


TREBALL FINAL DE GRAU



Universitat de Lleida
Escola Politècnica Superior

Grau en Enginyeria Mecànica

"Anàlisi d'ocupació d'edificis universitaris basat
en dades Wi-Fi per reduir-ne el consum
energètic"

Autor:
Guillem Hernández Prat

Directors:
Dr. Marc Medrano Martorell i Dr. Jorge Cipriano Líndez

Lleida, juny del 2017

Continguts

Resum	3
Motivació.....	3
1. Objectius.....	4
2. Introducció i context	5
2.1. Necessitat de reduir la despesa energètica.....	5
2.2. Estat de l'ús de l'anàlisi de dades Wi-Fi com a indicador d'ocupació	7
2.3. Definint ocupació; resolució de la informació.....	9
2.4. Comparació de diferents mètodes per a l'obtenció de dades d'ocupació	10
3. Abast.....	11
4. Històric d'accés Wi-Fi	12
5. Tractament de les dades	13
6. Històric de consum elèctric	13
7. Estudi i comparació del consum elèctric amb les dades d'accés Wi-Fi	14
8. Resultats i discussió	16
8.1. Edifici Rectorat	16
8.1.1. Tots els dies	16
8.1.2. Sense dies de tancament.....	21
8.2. CREA.....	26
8.2.1. Tots els dies	26
8.2.2. Sense dies de tancament.....	31
8.3. Taula de resultats numèrics.....	37
9. Conclusions	37
10. Propostes de millora	38
11. Agraïments.....	40
12. Referències bibliogràfiques i bibliografia consultada	40
Annex – Codi R emprat.....	43

Resum

S'han tractat estadísticament les dades del nombre de connexions als punts d'accés Wi-Fi de tots els edificis de la Universitat de Lleida, així com les del consum elèctric dels mateixos, concatenant-les horàriament durant les últimes 5 setmanes de l'any 2016. Aquestes dades han estat analitzades per a dos edificis amb perfils d'ús diferents, arribant a la conclusió de que en edificis d'alta ocupació, de caire educatiu i amb biblioteca hi ha una correlació no gaire fina entre nombre de dispositius connectats a la xarxa Wi-Fi i consum energètic de l'edifici, mentre que en edificis especialitzats en recerca i d'ocupació menor aquesta correlació és encara més baixa.

S'han proposat mesures basades en aquesta anàlisi amb les que reduir el consum elèctric d'edificis universitaris. Algunes d'aquestes mesures requeririen l'automatització de l'anàlisi per a poder-la realitzar en temps real, no així la que tindria un impacte potencialment més significatiu, consistent en identificar patrons d'ocupació als edificis i inactivant sistemes consumidors d'energia durant els períodes de no ocupació. S'ha estimat un estalvi d'uns 74.500 kWh, 48,4 t de CO₂ i 9.680 € anuals de dur a terme aquesta mesura a l'edifici del Rectorat.

Motivació

Vivim en una societat global que cada cop es fa un ús més intensiu de l'energia: la tendència arreu del món ha estat que la demanda energètica es dispari a mesura que les condicions econòmiques milloren. Aquest consum energètic té conseqüències negatives sobre el medi ambient i, per tant, sobre la societat. Els edificis en el seu conjunt són el major consumidor d'energia del món, amb 112 EJ (més de $3 \cdot 10^{10}$ MWh) d'energia final consumits l'any 2005, representant el 34%, lleugerament per sobre del transport (Medrano, 2014).

Tot i que hi ha avenços importants en l'eficiència de les instal·lacions, per exemple la transició de llums incandescents a fluorescents i posteriorment a

díodes LED el malbaratament d'energia segueix incrementant. De fet, societats freqüentment identificades com a ecologistes tals com Alemanya o els Països Baixos es troben paradoxalment entre els majors consumidors d'energia per càpita de tot el món (World Bank, 2014).

L' "estratègia alemanya", consistent en maximitzar l'eficiència de les instal·lacions, és molt poc efectiva si s'utilitza com a pretext per no fer canvis més profunds que necessàriament impliquen reduir l'ús d'aquestes instal·lacions. No s'hi guanya res en que una bombeta consumeixi la meitat d'electricitat si es deixa engegada el doble de temps o es passa a utilitzar-ne dues.

Així doncs, és necessari un canvi de paradigma: **cal reduir l'ús d'instal·lacions i màquines que requereixen energia per funcionar**, queda patent que amb millorar-ne l'eficiència no és suficient.

Les possibles millores que es puguin obtenir de l'estudi realitzat en aquest treball queden en algun lloc entremig de la millora de la eficiència i la reducció de l'ús de les instal·lacions, cal tenir-ho present a l'hora d'implantar-les.

Amb aquest treball l'autor desitja poder contribuir a la generació de coneixement per a reduir el consum energètic, concretament en edificis d'alta ocupació.

1. Objectius

1. Descobrir la possible correlació entre ocupació i consum energètic, així com amb el número de dispositius connectats als punts Wi-Fi i el consum energètic.

2. Proposar canvis fonamentats en l'estudi previ per assolir una reducció significativa del consum energètic amb una inversió econòmica tan reduïda com sigui possible.¹

2. Introducció i context

2.1. Necessitat de reduir la despesa energètica

El consum mundial d'energia ha augmentat a un ritme molt elevat quasi incessantment els últims dos segles, degut en gran part a la revolució industrial començada a finals del segle XVIII. Aquests nous processos productius, dependents de maquinària en moltes ocasions, requerien grans quantitats d'energia i van permetre un desenvolupament econòmic sense precedents en la història de la humanitat, que va permetre l'adopció massiva de les noves tecnologies que han anat sorgint des d'aleshores com a conseqüència del progrés científic. Aquestes tecnologies, amb l'objectiu final de millorar les condicions de vida de les persones, en molts casos són també grans consumidors d'energia. Ginyes com l'automòbil, l'avió o, en el sector dels edificis, el compressor usat en aparells d'aire condicionat o bombes de calor en són exemples.

Amb l'excepció conseqüència d'algunes crisis productives, comercials o financeres que hi han tingut un impacte menor, el consum energètic per càpita no ha parat d'augmentar, i no es preveu que deixi de fer-ho en el futur proper. La població mundial mostra un comportament similar, amb un increment notable any rere any.

¹ S'han utilitzat expressions poc concretes tals com "reducció *significativa*" i "inversió econòmica *tan reduïda com sigui possible*" degut al desconeixement de l'autor de la magnitud de les xifres energètiques i econòmiques considerades acceptables per la Universitat de Lleida.




Figura 1. Consum global d'energia classificat per tipus (Tverberg 2012)

El consum d'energia porta associats diversos problemes mediambientals, socials i econòmics. El canvi climàtic és, probablement, el que més ressò ha tingut: l'ús de combustibles fòssils genera, entre altres, diòxid de carboni.




Figura 2. Concentració de diòxid de carboni a l'atmosfera 1960 – 2013 (NOAA/Scripps Institution of Oceanography 2013)

El diòxid de carboni és un gas d'efecte d'hivernacle: la seua presència a l'atmosfera evita que part de la radiació infraroja emesa per la Terra escapi a l'espai, augmentant-ne la temperatura mitjana. Aquest efecte és imprescindible per a la vida a la Terra, de no produir-se la temperatura mitjana al planeta seria

d'uns -15 °C, 30 °C per sobre de la temperatura mitjana actualment (Columbia University 2007). L'estimació generalitzada és que la temperatura ja ha augmentat entre 1 i 2 °C degut a aquestes emissions d'origen humà. Les conseqüències d'aquest augment tan brusc de la temperatura del planeta són molt greus, i poden ser devastadores si el problema segueix creixent: alteracions del clima a nivell local (sequeres i inundacions cròniques), fusió de grans masses de gel i augment del nivell del mar, pèrdua de biodiversitat, escassetat de recursos que forçaria comunitats senceres a marxar fora de les seves terres, entre altres (European Commission 2017).

En molts casos aquestes conseqüències afectarien amb especial duresa a països sense recursos per mitigar-les. Com a exemple el vuitè estat més poblat del món, Bangla Desh, és extremadament vulnerable a la crecuda del nivell del mar: amb una pujada de només 1 m el 50% del territori quedaria sota les aigües (Govern de Bangla Desh 2008).

Tot i que la transició a fonts d'energia renovables mitigarien aquest i altres problemes dels combustibles fòssils i nuclears, ara per ara estem molt lluny d'assolir-la, i tot i així no es solucionaria el problema, només s'esmorteria. Tot i ser millors des d'un punt de vista ecològic, social, estratègic i econòmic a llarg termini, les fonts d'energia renovables presenten altres problemes específics al tipus de font que s'utilitzi: l'energia hidrològica molts cops comporta problemes de cabal dels rius i hi pot afectar la vida, etc. Per tant, tampoc resulten perfectes.

Així doncs, l'única opció raonable a l'empitjorament del canvi climàtic passa sí o sí per la reducció de l'ús d'energia.

2.2. Estat de l'ús de l'anàlisi de dades Wi-Fi com a indicador d'ocupació

Tot i que mitjançant l'anàlisi d'indicadors indirectes i, més en concret, de punts d'accés a Internet per obtenir informació sobre l'ocupació d'edificis és una pràctica iniciada molt recentment i encara poc estudiada, la detecció

d'ocupació porta dècades emprant-se en molts edificis per reduir-ne el consum energètic, per exemple amb detectors de moviment que activen la il·luminació en els passadissos d'hotels. Mètodes com aquest són eficaços, senzills i barats però tenen deficiències importants de *resolució* (terme desenvolupat al subapartat 2.1 Definint ocupació; resolució de la informació) que en limiten molt el rang d'utilització: és per això que els ja esmenats sensors de moviment s'utilitzen quasi exclusivament per controlar l'enllumenat i, a més a més, en zones i situacions molt concretes tals com passadissos.

Aquest treball pretén explorar el potencial de l'ús de punts d'accés a Internet sense cables Wi-Fi per tal d'estimar l'ocupació d'edificis públics, així com l'aprofitament d'aquesta informació per reduir el consum energètic dels mateixos edificis.

L'estudi s'ha dut a terme sobre els punts d'accés Wi-Fi de tots els edificis de la Universitat de Lleida que són, a priori, ideals per utilitzar tècniques d'anàlisi d'aquest tipus ja que es tracta d'edificis públics grans, amb molta ocupació i majoritàriament ocupats per estudiantat universitari, al que se li pressuposa una forta tendència a connectar-se a Internet mitjançant xarxes sense fil; un major percentatge d'ocupants connectats als punts d'accés implica una major precisió de la informació obtinguda i analitzada.

(Richardson, Thomson i Infield 2008) Creen un model d'ocupació d'ocupants actius (no dormint) en edificis residencials al Regne Unit a partir de dades d'alta resolució, especialment ocupació i temporal (10 minuts) obtingudes mitjançant enquesta.

(Martani, et al. 2012) Estudien la relació entre consum energètic (detallat per tipus) i ocupació mitjançant indicadors indirectes en dos edificis d'alta ocupació. Arriben a la conclusió que factors com la temperatura exterior tenen un impacte molt més important en la demanda energètica que l'ocupació, mentre que en alguns sistemes menors en quant a consum d'energia predomina l'ocupació.

2.3. Definint ocupació; resolució de la informació

Segons el proposat per (Melffi, et al. 2011), l'ocupació d'un edifici es pot definir a partir de les escales de *resolució* i *precisió*; és important conèixer la resolució de la informació tractada per tal de conèixer-ne les limitacions a l'hora d'analitzar-la. La resolució consta de tres dimensions: la d'ocupants, l'espacial i la temporal. En el cas de les dades tractades en aquest treball la resolució d'ocupants és relativament baixa: no inclou

l'activitat que desenvolupen els ocupants ni els identifica, i degut a que és una mesura indirecta ni tan sols es pot saber exactament el nombre de persones que hi ha dins l'edifici. Tot i això, és possible fer estimacions relatives del nivell d'ocupació de l'edifici. En quant a la resolució espacial, encara que més fina, també presenta certa ambigüïtat, ja que els punts d'accés Wi-Fi estan distribuïts per cobrir zones específiques dels edificis però en diversos punts es superposen senyals de diferents punts d'accés. Així doncs, es pot afirmar amb seguretat que és possible tenir informació detallada per a cada edifici, però no de la posició a l'interior del mateix.

Finalment, la resolució temporal és virtualment il·limitada amb aquest mètode: les dades obtingudes són lectures amb una freqüència de 10 minuts, i aquesta resolució es podria augmentar encara més si es desitgés. La resolució temporal d'aquestes dades és, de fet, tan alta que a l'anàlisi s'ha hagut de reduir deliberadament a freqüència horària per tal de sincronitzar les dades d'accés Wi-Fi amb les de consum elèctric dels edificis.

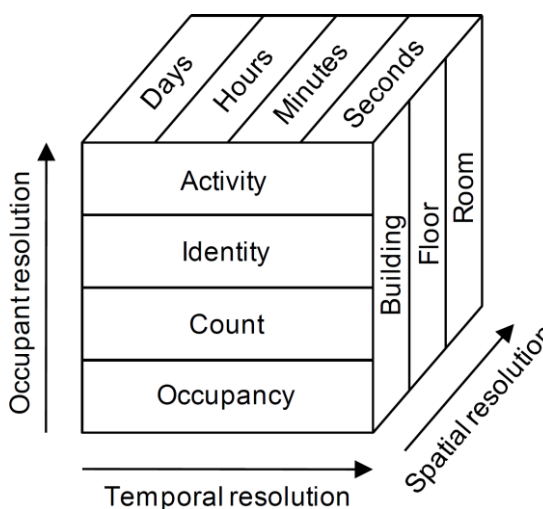


Figura 3. Resolució en les dades d'ocupació (Melffi, et al. 2011)

2.4. Comparació de diferents mètodes per a l'obtenció de dades d'ocupació



Figura 4. Punt d'accés Wi-Fi (esquerra) i detector de moviment (dreta) a l'edifici CREA

Cadascun dels possibles mitjans d'obtenció de dades d'ocupació en edificis té unes característiques que el diferencien de la resta i en determinen la idoneïtat en funció de les peculiaritats l'edifici o sala i l'objectiu pel que es volen utilitzar. A continuació es fa una breu comparativa entre alguns d'aquests mitjans, existents o possibles:

Tipus	Mètode	Resolució i precisió d'ocupants	Resolució i precisió espacial	Resolució i precisió temporal
Directe	Detector de moviment	Resolució mínima (ocupat SÍ/NO), precisió molt alta	Resolució excel·lent, precisió molt alta sempre que hi hagi moviment	Resolució excel·lent, precisió excel·lent sempre que hi hagi moviment
	Sensor d'infrarojos bàsic	Resolució mínima (ocupat SÍ/NO), precisió excel·lent	Resolució excel·lent, precisió excel·lent	Resolució excel·lent, precisió excel·lent
	Sensor d'infrarojos avançat	Resolució molt alta (identificació	Resolució excel·lent, precisió mitjana	Resolució excel·lent,

		d'ocupants), precisió baixa		precisió excel·lent
	Contador de pas	Resolució baixa (quantitat d'ocupants), precisió molt alta	Resolució en funció del posicionament, precisió excel·lent	Resolució molt alta, precisió excel·lent
Indirecte	Connexions Wi-Fi	Resolució molt alta (identificació d'ocupants), precisió baixa	Resolució en funció de diversos factors, precisió baixa	Resolució excel·lent, precisió excel·lent
	Potència calorífica generada	Resolució excel·lent (identificació d'activitats), precisió molt baixa	Resolució excel·lent, precisió molt alta	Resolució baixa, precisió molt baixa

Taula 1. Diferents mètodes de detecció d'ocupació

3. Abast

S'han analitzat estadísticament els perfils de connexions Wi-Fi i consum elèctric de dos edificis de la Universitat de Lleida durant les últimes 5 setmanes de l'any 2016 amb dades de freqüència horària. Les mesures proposades per a reduir el consum dels edificis han estat basades en les conclusions extretes dels resultats d'aquesta anàlisi.

4. Històric d'accés Wi-Fi

S'ha obtingut l'històric de les dades d'accés als punts d'accés Wi-Fi de l'últim any en un fitxer d'extensió .csv cortesia de Judith Pintó, tècnica de sistemes de l'Àrea de Sistemes d'informació i Comunicacions de la UdL. Els fitxers CSV consisteixen en valors de text en format ASCII separats per comes. La informació d'aquest fitxer s'estructura en una taula com la següent:

clock	itemid	itemname	value
Data, hora, fus horari	Identitat del punt d'accés	Nom del punt d'accés	Número de dispositius connectats

Taula 2. Estructura de les dades d'accés Wi-Fi

La primera fila és l'encapçalament de la taula, amb els títols de cada columna en anglès. Les primeres files d'aquest document són les següents:

clock	itemid	itemname	value
2016-11-26 13:03:16+00:00	61395	wlanAPClientNumber_AR3-260	0
2016-11-26 13:13:17+00:00	61395	wlanAPClientNumber_AR3-260	0
2016-11-26 13:23:16+00:00	61395	wlanAPClientNumber_AR3-260	0

Taula 3. Primeres columnes del fitxer d'accés Wi-Fi

Totes les columnes proporcionen informació rellevant i necessària pel seu correcte estudi, excepte les columnes *itemid* i *itemname* que són redundants ja que ambdues identifiquen cada punt d'accés: es pot prescindir d'una d'elles. Així doncs, amb només tres columnes d'informació queda registrat per a cada punt d'accés el número de connexions actives i en quin moment, per a intervals de 10 minuts. Aquesta taula, així com la resta de taules de dades emprades en l'anàlisi s'ha emmagatzemat i tractat com a *dataframe*. Un dataframe (o data frame, entrant de dades en català) és un objecte usat en R per emmagatzemar taules de dades; és una llista de vectors d'igual longitud especialment útil per a treballar amb vectors molt llargs.

5. Tractament de les dades

Mitjançant el programa R [versió 3.2.2 x64] sota la interfície RStudio [versió 1.0.136 a 32 bits] i el paquet R Markdown instal·lat s'ha tractat el fitxer de l'històric de les dades d'accés als PA Wi-Fi.

S'ha escollit aquest programa degut a que l'extensió de les dades és tal que seria impossible tractar-les manualment. Altres programes de matemàtiques tenen limitacions que permetrien tractar el fitxer però molt inconvenientment; per a fer-se una idea, programes especialitzats com el LibreOffice Calc o la seva alternativa propietària Microsoft Excel només poden mostrar un terç de totes les dades del document. R és probablement el programa especialitzat en estadística més capaç, la qual cosa és idònia degut a que es requereix un tractament estadístic de la informació. La interfície RStudio fa el programa més visual i acollidor a usuaris inexperts.

Abans de començar amb les dades d'aquest fitxer cal importar un seguit de llibreries que automatitzen moltes accions a dur a terme a posteriori. Aquests paquets de llibreries són "*magrittr*", "*data.table*", "*ggplot2*", "*tidyr*", "*reshape2*", "*dplyr*", "*lubridate*", "*AnomalyDetection*" i "*zoo*". Seran carregats sempre abans de començar cap altra tasca que els requereixi.

Un cop fet això calia importar el fitxer per començar a treballar-hi. A partir d'aquí es va formatar la primera columna (*date*) com a data, en format Dia/Mes/Any Hora:Minut, i l'última columna (*value*) com a número. La columna itemid és eliminada degut a la redundància de la informació que aporta: a l'eliminar un 25% de les dades era d'esperar que l'R fos capaç de treballar més eficientment.

6. Històric de consum elèctric

S'ha obtingut l'històric de consum elèctric de cada edifici durant l'últim any en diversos fitxers .csv cortesia d'en Josep Maria Martí Puigvert, estudiant del Màster en Enginyeria Industrial a la Universitat de Lleida que està realitzant un

Treball de Final de Màster sobre l'anàlisi detallat del consum elèctric d'edificis de la universitat. La informació d'aquests fitxers s'estructura en una taula com la següent:

ID	*Data*	*Hora*	*Consum*
Identitat de l'edifici	Dia, mes i any	Hora (format 24h)	Valor del consum elèctric de l'edifici durant l'última hora en kWh

Taula 4. Estructura de les dades de consum elèctric

A diferència de l'històric d'accés Wi-Fi, aquestes taules no tenen encapçalaments encara que a la representació anterior s'hi hagin inclòs. Degut a que els fitxers ja són independents per cada edifici la columna *ID* és irrellevant i per tant ha estat eliminada per a agilitzar el processament de les dades. Les columnes *Data* i *Hora* han estat fusionades en una sola columna *time*, quedant així dataframes de consum amb dues columnes: *time* i *Consum*. L'R, per defecte, interpreta el contingut d'aquest dataframe com a cadena de caràcters, i per a tractar-lo adequadament és necessari identificar la columna *time* com a data i hora i la columna *Consum* com a valor numèric.

7. Estudi i comparació del consum elèctric amb les dades d'accés Wi-Fi

S'han concatenat els dataframes de l'històric d'accés Wi-Fi i l'històric de consum elèctric segons la data i hora, tractant-lo i generant un dataframe per a cada edifici de set columnes, les tres primeres amb la informació imprescindible:

Group.1	X	V4
Data i hora amb freqüència horària i format "Any-mes-dia hh:mm:ss"	Número de dispositius connectats a la xarxa Wi-Fi	Consum elèctric durant l'última hora en kWh

Taula 5. Estructura del dataframe (primeres 3 columnes)

I les següents amb informació obtinguda a partir de la de les tres primeres que serà necessària per a fer l'anàlisi:

SetmanaAny	HoraSetmana	WifiNormalitzat	ConsumNormalitzat
Any i setmana de les dades en format "Any-setmana"	Número d'hores transcorregudes des de l'inici de la setmana	Número de dispositius connectats a la xarxa Wi-Fi dividit pel número màxim de dispositius connectats en qualsevol moment del període analitzat	Consum elèctric durant l'última hora dividit pel consum màxim en qualsevol moment del període analitzat

Taula 6. Estructura del dataframe (últimes 4 columnes)

Aquesta concatenació s'ha dut a terme de tal manera que s'exclouï qualsevol entrada que no sigui present als dos dataframes inicials, el que significa que, encara que comencin i acabin en moments diferents només es tindrà en compte el rang de temps en el que es té informació tant d'accés Wi-Fi com de consum elèctric.




Figura 5. Diagrama de la concatenació de les dades

Sobre aquestes dades definitives s'ha analitzat primer la distribució temporal d'accessos Wi-Fi i consum alhora per identificar incoherències en les dades, així com corroborar que la distribució és tal com s'espera: consum i dispositius connectats

a la xarxa en nivells mínims durant les hores en les quals els edificis romanen tancats, tals com les nits, caps de setmana i dies festius.

Un cop realitzada aquesta anàlisi preliminar es va procedir a analitzar la possible correlació entre accessos Wi-Fi i consum elèctric, edifici a edifici.

8. Resultats i discussió

S'han seleccionat dos edificis amb usos universitaris típics, però amb un caire el més diferenciats possible per a conèixer els casos extrems: per una banda l'edifici del Rectorat, amb una ocupació molt elevada, on s'hi imparteixen classes i inclou una biblioteca.

L'altre edifici es tracta del CREA, al campus de Capponet; degut a l'especialització en recerca és un edifici d'oficines i laboratoris amb una ocupació baixa en comparació amb la majoria d'edificis de la universitat.

8.1. Edifici Rectorat

8.1.1. Tots els dies

En l'edifici del rectorat s'hi observa, com era esperable, que l'activitat Wi-Fi es concentra durant les hores en què l'edifici està obert, amb un creixement molt elevat a partir de les 8h fins arribar al pic de connexions a les 11h. A partir d'aquest moment s'inicia un descens de l'activitat fins un mínim relatiu a les 14h que precedeix el màxim relatiu de la tarda, entre les 16 i 17h; a continuació el número de connexions va decaient fins les 22h, on arriba al mínim que es manté més o menys constant fins les 5h del dia següent. És remarcable que aquest mínim no arriba a les zero connexions, sinó que fluctua entre 20 i 60. Aquest comportament és consistent en tots els dies lectius analitzats, i es manté similar però amb menys connexions els dissabtes i diumenges que la biblioteca és oberta durant l'època d'exàmens (Fig. 6).

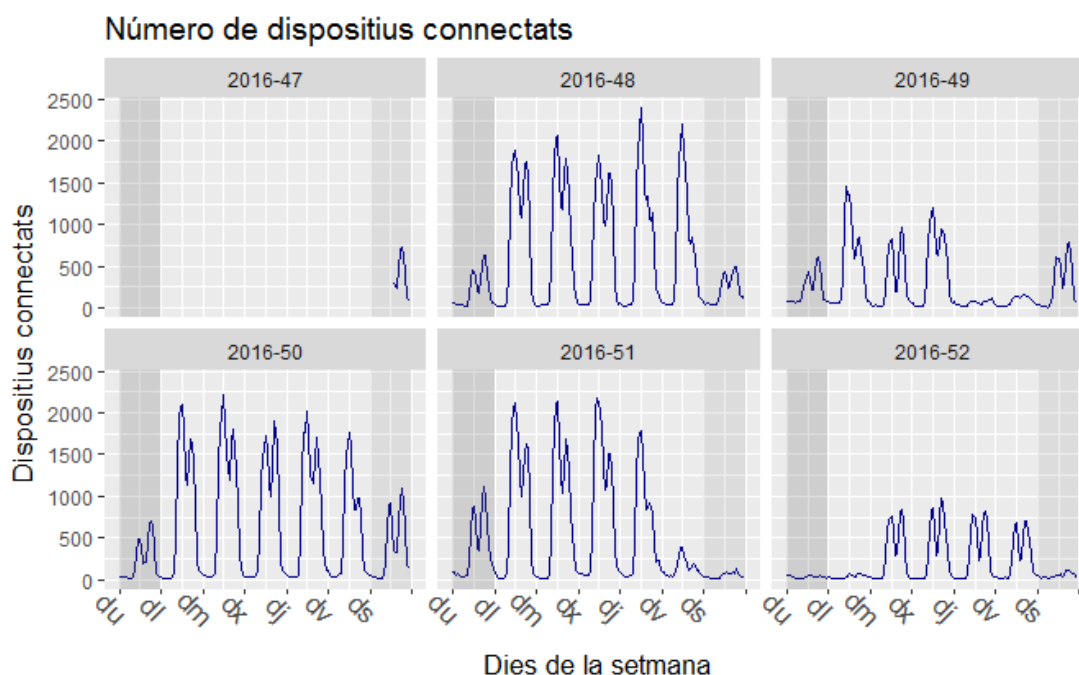


Figura 6. Nombre de connexions Wi-Fi al Rectorat

Pel que fa al consum elèctric de l'edifici, s'hi pot observar un clar ajustament al nombre de connexions durant les hores d'obertura al públic de l'edifici. Quan es troba tancat manté un consum estable d'entre 80 i 90 kW, inferior al de quan està ocupat però tot i així de vora el 25% del consum màxim de l'edifici en tot el període (Fig. 7).




Figura 7. Comparativa entre nombre de connexions (normalitzat) i consum elèctric (normalitzat) al Rectorat

Les dades de nombre de connexions i consum elèctric presenten una correlació amb una R^2 de 0,878. Aquest valor tan elevat [el màxim possible és 1] suggereix que la correlació és molt alta. La línia de regressió calculada segueix l'equació $y = \alpha + \beta x$, amb $\alpha = 85,54$ i $\beta = 0,092$. La variable y fa referència al consum elèctric en kWh, l' x al nombre de dispositius connectats al Wi-Fi, la constant α és el valor de y quan $x=0$ (conegut com a punt d'intercepció) i β és el valor del pendent de la recta. Hi ha una gran concentració de dades en el rang de consum <125 kWh que poden tenir un pes excessiu en aquest coeficient de determinació (Fig. 8).




Figura 8. Gràfic de dispersió entre nombre de connexions i consum elèctric al Rectorat

Per tal de verificar les assumpcions del model lineal del gràfic de la línia de regressió sobre el gràfic dispersió anterior (Fig. 8) s'han realitzat diverses anàlisis gràfiques:

En el gràfic Q-Q s'hi pot observar que els residus del model basat en aquesta recta de regressió lineal no segueixen una distribució normal (Fig. 9)




Figura 9. Gràfic Q-Q d'anàlisi del Rectorat amb tots els dies

En base al gràfic “residuals versus fitted”, es comprova que la variància dels residus és bastant homogènia per a valors elevats de consum (>180 kWh), però no pels valors baixos. Hi ha una correlació negativa, o descendent, entre residus i valors de consum al rang entre 80 i 180 kWh, la qual cosa indica que el model no és adequat per a consums baixos degut a un comportament no lineal que és incapaç de capturar (Fig. 10).




Figura 10. Gràfic “residuals versus fitted” del Rectorat amb tots els dies

El gràfic “residuals versus leverage” és útil per a identificar la presència de valors amb gran influència sobre la correlació a través del posicionament dels punts en el mateix i fora de la corba “Cook’s distance”. En aquest cas es veu que la majoria de punts tenen poca influència, amb l’excepció del 119. Aquest punt correspon a l’1 de desembre de 2016 a les 11h, que és l’hora amb el major nombre de connexions Wi-Fi registrades de tot el període: 2.396. El consum elèctric mitjà en aquesta hora va ser de 251 kW. Aquestes dades, encara que elevades, són plausibles, ja que hi ha diversos dies que superen amb escreix les 2.000 connexions entre les 9 i les 12h i el major consum mitjà enregistrat és de 289 kW. (Fig. 11).




Figura 11. Gràfic "residuals versus leverage" del Rectorat amb tots els dies

El gràfic de funcions d'autocorrelació, o ACF, mostra una diferència entre valors positius i negatius que corrobora un mal ajust del model lineal (Fig. 12).




Figura 12. Gràfic ACF del Rectorat amb tots els dies

8.1.2. Sense dies de tancament

S'ha repetit l'anàlisi anterior pel mateix edifici però exclouent-hi els dies festius i caps de setmana per descobrir si és possible augmentar la precisió del model

d'aquesta manera. Els gràfics setmanals de nombre de connexions (Fig. 13) i de comparació amb els consums normalitzats (Fig. 14) són idèntics que per als gràfics amb tots els dies del període a excepció de tenir dies eliminats; no es tornen a comentar degut a que la interpretació n'és idèntica.

Aquests dos gràfics s'han generat a mode de comprovació.

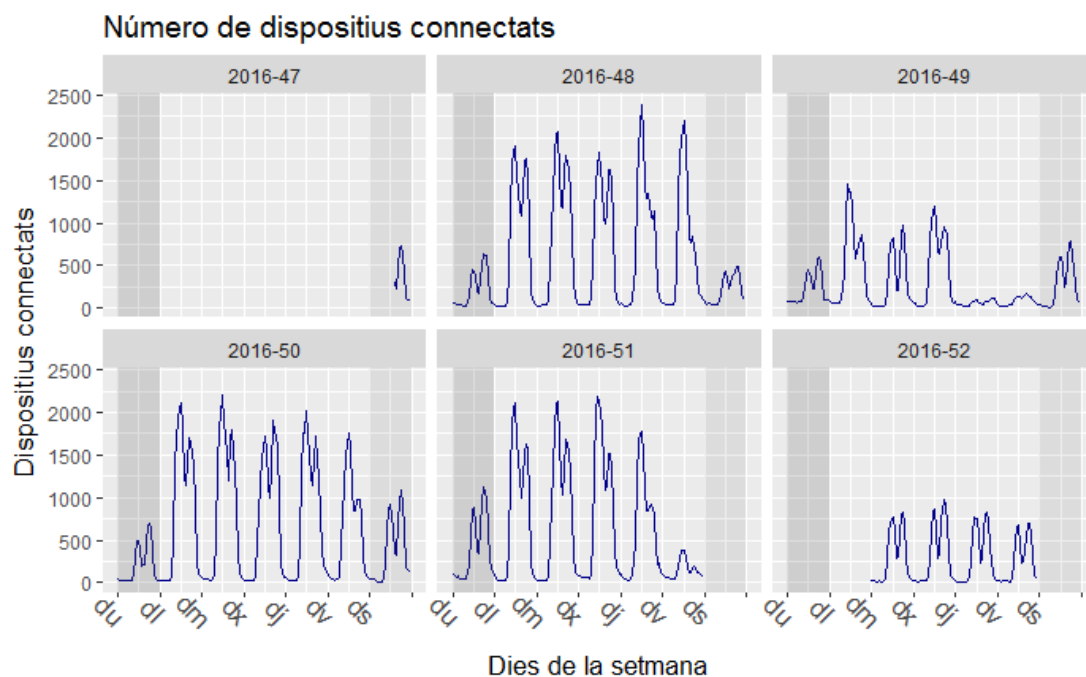


Figura 13. Nombre de connexions Wi-Fi al Rectorat sense dies de tancament

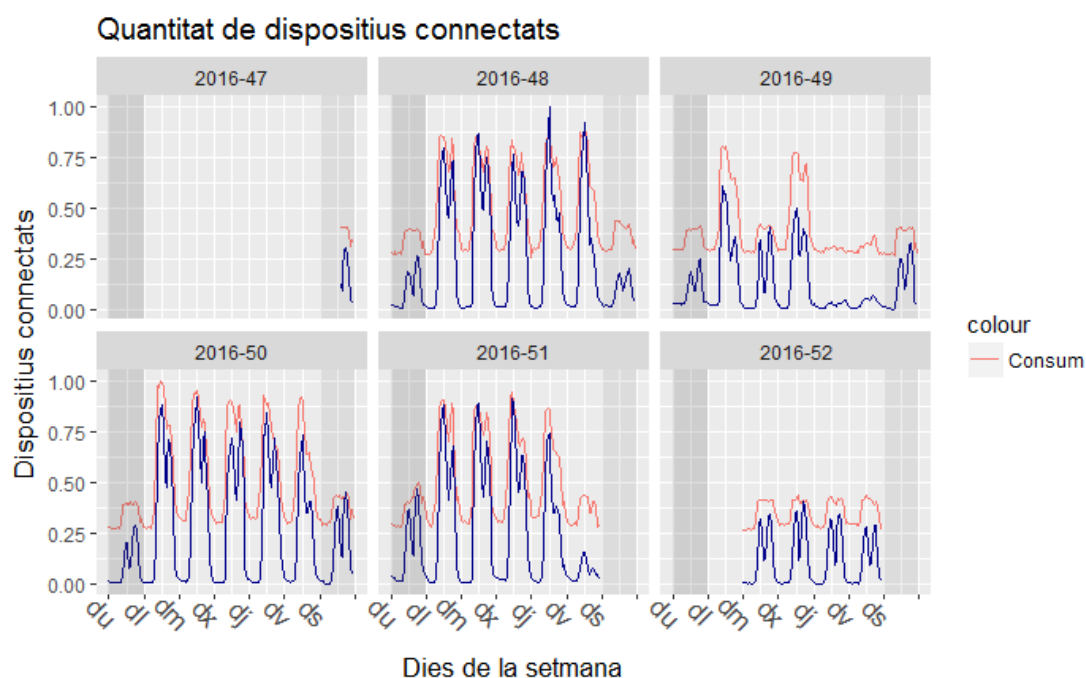


Figura 14. Comparativa entre nombre de connexions (normalitzat) i consum elèctric (normalitzat) al Rectorat sense dies de tancament

Les dades de nombre de connexions i consum elèctric presenten una correlació amb una R^2 de 0,872. Aquest valor segueix essent molt elevat, però és lleugerament inferior a l'obtingut en la correlació amb tots els dies. Tot i així, es pot concloure que la correlació segueix sent molt alta. La línia de regressió calculada segueix l'equació $y = \alpha + \beta x$, amb $\alpha = 87,57$ i $\beta = 0,091$. La variable y fa referència al consum elèctric en kWh, l' x al nombre de dispositius connectats al Wi-Fi, la constant α és el valor de y quan $x=0$ (conegut com a punt d'intercepció) i β és el valor del pendent de la recta (Fig. 15). Tot i no ser igual, aquesta recta és molt semblant a la calculada sense ometre els dies de tancament de l'edifici. Segueix havent-hi una quantitat important de punts en la regió de consum < 125 kWh (Fig. 8).




Figura 15. Gràfic de dispersió entre nombre de connexions i consum elèctric al Rectorat sense dies de tancament

Per tal de verificar les assumpcions del model lineal del gràfic de la línia de regressió sobre el gràfic dispersió anterior (Fig. 15) s'han realitzat les mateixes anàlisis gràfiques que anteriorment:

El gràfic Q-Q obtingut és molt similar al del mateix edifici amb tots els dies del període, i s'hi pot observar que els residus del model basat en aquesta recta de regressió lineal tampoc segueixen una distribució normal (Fig. 16)




Figura 16. Gràfic Q-.Q d'anàlisi del Rectorat sense dies de tancament

El gràfic “residuals versus fitted” sota aquest subconjunt de punts també és quasi idèntic al traçat per a tots els dies del període; se’n fa la mateixa interpretació (Fig. 17).




Figura 17. Gràfic “residuals versus fitted” del Rectorat sense dies de tancament

El gràfic “residuals versus leverage” és també extremadament similar al del conjunt de dades amb totes les hores, i presenta els mateixos punts “palanca” a les mateixes posicions (Fig. 18).




Figura 18. Gràfic "residuals versus leverage" del Rectorat sense dies de tancament

Altres cop, el gràfic de funcions d'autocorrelació mostra els problemes que presenta el model lineal proposat (Fig. 19).




Figura 19. Gràfic ACF del Rectorat sense dies de tancament

8.2. CREA

8.2.1. Tots els dies

A l'edifici CREA del campus de Cappont el patró de connexions és similar però no idèntic: hi ha dies en els que s'hi produeixen més de dos pics de connexions, o que s'hi connecten més dispositius a la tarda que al matí, o que presenten un sol pic: és menys consistent. Això podria ser degut a que, per a qualsevol moment donat, hi ha vora 10 cops més dispositius connectats al rectorat que al CREA, la qual cosa implica més desviació estàndard. Anàlogament a l'altre edifici analitzat, el nombre de dispositius connectats no baixa fins a zero quan l'edifici és tancat (p.e. durant les nits), sinó que arriba a un mínim estable d'entre 6 i 10 connexions. (Fig. 20).

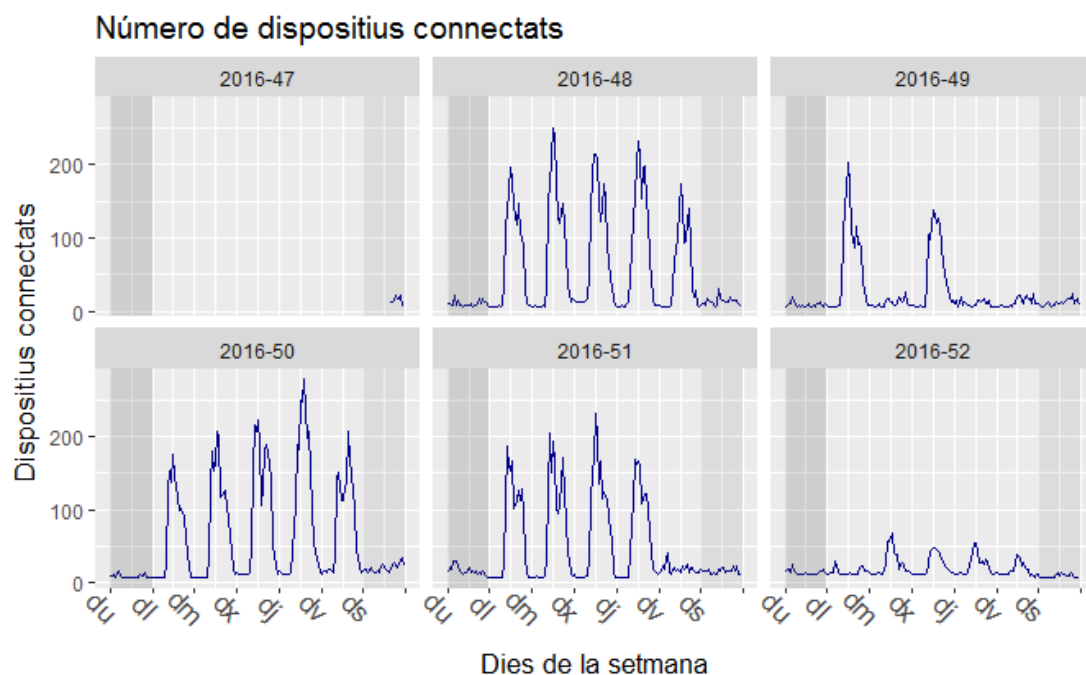


Figura 20. Nombre de connexions Wi-Fi al CREA

El consum elèctric, tal i com passa amb el rectorat, mostra una certa correlació amb el nombre de connexions però molt més subtil. S'observa un comportament estrany en el consum d'aquest edifici: tot i que, en general, retorna a un mínim estable d'entre 13 i 15 kW totes les nits i dies no laborables, hi ha diversos dies en els que consumeix més energia de l'esperable. També s'ha detectat un probable error de mesurament, ja que entre el 12 de desembre

a les 19h i el 15 a les 14h hi ha una lectura constant de 31,73 kWh consumits cada hora. És poc raonable pensar que l'edifici realment ha mantingut constant aquest consum cada hora amb una precisió de centèsimes de kWh durant quasi tres dies consecutius (Fig. 21).




Figura 21. Comparativa entre nombre de connexions (normalitzat) i consum elèctric (normalitzat) al CREA

Les dades de nombre de connexions i consum elèctric presenten una correlació amb una R^2 de 0,484. Aquest valor suggereix que hi existeix correlació però no és tan elevada com a l'edifici del Rectorat. La línia de regressió calculada segueix l'equació $y = \alpha + \beta x$, amb $\alpha = 16,9$ i $\beta = 0,129$. La variable y fa referència al consum elèctric en kWh, l' x al nombre de dispositius connectats al Wi-Fi, la constant α és el valor de y quan $x=0$ (conegut com a punt d'intercepció) i β és el valor del pendent de la recta. (Fig. 22)




Figura 22. Relació entre nombre de connexions i consum elèctric al CREA

Per tal de verificar les assumpcions del model lineal del gràfic de la línia de regressió sobre el gràfic dispersió anterior (Fig. 22) s'han realitzat diverses anàlisis gràfiques:

En el gràfic Q-Q s'hi pot observar que els residus sobre el model basat en aquesta recta de regressió lineal no segueixen una distribució normal (Fig. 23), encara menys que en l'altre edifici analitzat.




Figura 23. Gràfic Q-Q d'anàlisi del CREA amb tots els dies

Al “residuals versus fitted”, es comprova que la variança dels residus és bastant homogènia per a valors de consum superiors als 23 kWh; no així pels que són inferiors. Hi ha una correlació negativa, o descendent, entre residus i valors de consum en un rang que acaba als 25 kWh, la qual cosa indica que el model tampoc és adequat per a consums baixos degut a un comportament no lineal que és incapaç de capturar (Fig. 24).




Figura 24. Gràfic “residuals versus fitted” del CREA amb tots els dies

En aquest gràfic “residuals versus leverage”, així com al de l’edifici Rectorat, la majoria de punts tenen poca influència (Fig. 25). L’excepció més notable és el 456. Aquest punt correspon al 15 de desembre de 2016 a les 13h, que és l’hora amb el major nombre de connexions Wi-Fi registrades de tot el període: 279. El consum elèctric mitjà en aquesta hora va ser de 31,73 kW, però es troba en el període sospitosos d’error degut al consum constant durant moltes hores. La següent hora amb més connexions en va tenir 251.




Figura 25. Gràfic “residuals versus leverage” del CREA amb tots els dies

El gràfic de funcions d’autocorrelació ACF (Fig. 26) mostra una tendència molt forta als valors positius, la qual cosa és un altre indicador de que el model lineal proposat no és efectiu descrivint acuradament el comportament real.




Figura 26. Gràfic ACF del CREA amb tots els dies

8.2.2. Sense dies de tancament

Anàlogament a l'edifici del Rectorat, pel CREA també s'ha repetit l'anàlisi excloent-hi els dies en què l'edifici es trobava tancat al públic. En el cas del CREA, a més a més, també s'han omès els dies 13, 14 i 15 de desembre degut a les lectures de consum elèctric sospitoses de ser errònies. Els dos gràfics setmanals de nombre de connexions (Fig. 27) i de comparació amb els consums normalitzats (Fig. 28), realitzats a mode de comprovació, són mostrats seguidament:

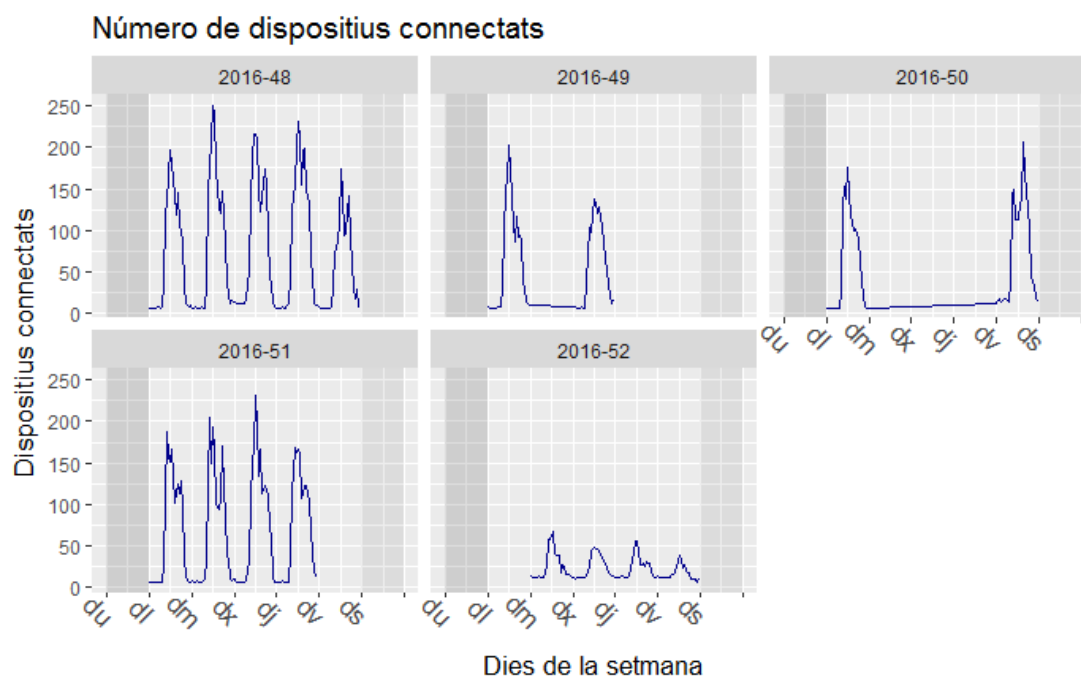


Figura 27. Nombre de connexions Wi-Fi al CREA sense dies de tancament

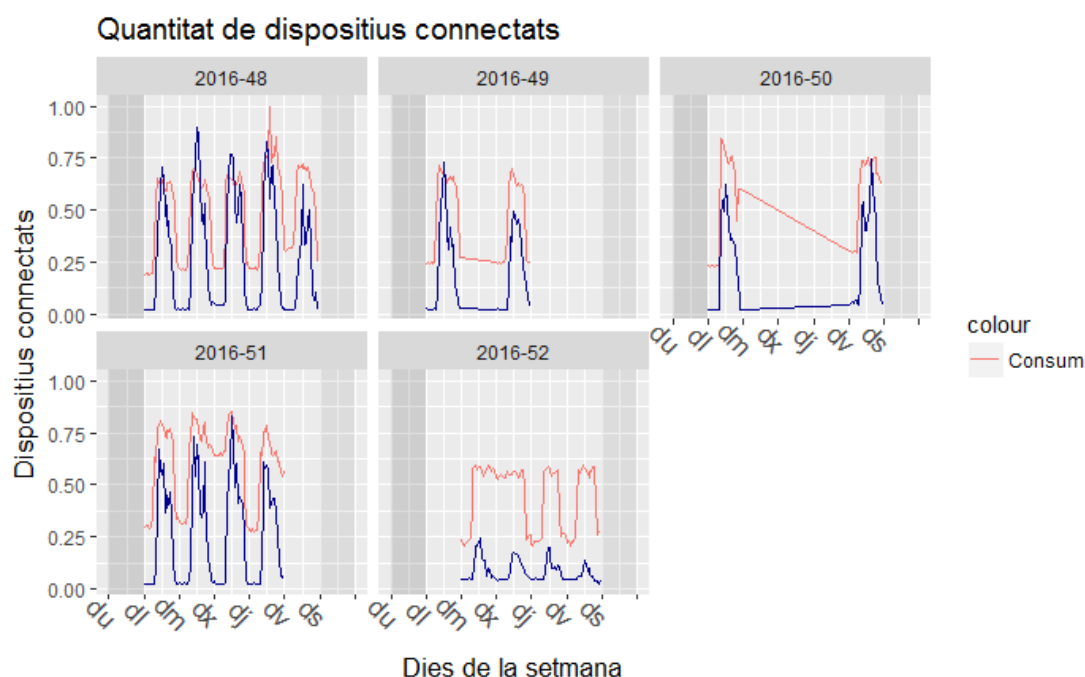


Figura 28. Comparativa entre nombre de connexions (normalitzat) i consum elèctric (normalitzat) al CREA sense dies de tancament

Les dades de nombre de connexions i consum elèctric presenten una correlació amb una R^2 de 0,539. Això indica una major correlació quan no es tenen en compte els dies de tancament ni les possibles lectures errònies que

amb tot el conjunt de dades, al contrari que en el cas de l'edifici del Rectorat. Tot i no arribar al nivell de correlació tan elevat mostrat a l'altre edifici, és una clara millora respecte l'anàlisi amb tots els dies del període i apunta a un augment de la fiabilitat. La línia de regressió calculada segueix l'equació $y = \alpha + \beta x$, amb $\alpha = 12,71$ i $\beta = 0,124$. La variable y fa referència al consum elèctric en kWh, l' x al nombre de dispositius connectats al Wi-Fi, la constant α és el valor de y quan $x=0$ (conegut com a punt d'intercepció) i β és el valor del pendent de la recta (Fig. 29). Aquesta recta és semblant a l'obtinguda per a tot el període estudiat (Fig. 22) però la diferència és de certa entitat, especialment al comparar-la amb la diferència entre les dues rectes obtingudes per a l'altre edifici.




Figura 29. Gràfic de dispersió entre nombre de connexions i consum elèctric al CREA sense dies de tancament

Per tal de verificar les assumpcions del model lineal del gràfic de la línia de regressió sobre el gràfic dispersió anterior (Fig. 29) s'han realitzat diverses anàlisis gràfiques:

En el gràfic Q-Q s'hi pot observar que els residus sobre el model basat en aquesta recta de regressió lineal no segueixen una distribució normal (Fig. 30), però s'hi atansen visiblement més que en el gràfic obtingut per a tot el període (Fig. 23), especialment en els punts dins el rang $x=-1$ i $x=0$. Això és un indicador

de que, tot i que el model segueix sense ajustar gaire bé, és millor en aquesta segona anàlisi.




Figura 30. Gràfic Q-Q d'anàlisi del CREA sense dies de tancament

Al gràfic “residuals versus fitted” també s’hi demostra un comportament similar, amb la principal diferència de la desaparició de la regió decreixent per a consums inferiors a 15 kWh. Això també és un senyal d’un menor nombre i/o rellevància de comportaments no lineals no capturats pel model (Fig. 31).




Figura 31. Gràfic “residuals versus fitted” del CREA sense dies de tancament

Al gràfic “residuals versus leverage” (Fig. 32) s’hi produeix un canvi remarcable: els punts amb major influència sobre la correlació ja no són els que es trobaven en el període de lectures sospitoses (han estat obviats en aquest model) i són substituïts pel 37 i 38, que corresponen al 28 de novembre a les 2 i 3h de la nit. Aquests punts corresponen a dues hores amb consums elèctrics molt baixos (10,3 i 10 kWh, respectivament). 10 kWh és el consum més baix registrat, i el CREA va tenir aquest consum dos cops durant els dies analitzats, encara que no es tracta d’un consum extraordinàriament baix. En aquestes hores també es va enregistrar el número més baix de connexions amb un total de 6, però igualment raonable: aquest mínim és compartit entre quasi el 14% (56 de 408) de les hores analitzades.




Figura 32. Gràfic "residuals versus leverage" del CREA sense dies de tancament

En aquest cas, el gràfic ACF segueix indicant un mal funcionament del model lineal (Fig. 33).




Figura 33. Gràfic ACF del CREA sense dies de tancament

8.3. Taula de resultats numèrics

Aquests són els resultats numèrics amb el coeficient de determinació (R^2) i equació de la recta de regressió lineal calculats per a cadascun dels 4 casos analitzats. Cal tenir en compte que, tot i presentar un coeficient de determinació elevat, cap de les dues anàlisis del Rectorat mostren una correlació elevada com s'ha comprovat gràficament.

	Rectorat	Rectorat només oberts	CREA	CREA només oberts
Recta de regressió	$85,54 + 0,092x$	$87,57 + 0,091x$	$16,9 + 0,129x$	$12,71 + 0,124x$
R^2	0,878	0,872	0,484	0,539

Taula 7. Resultats numèrics

9. Conclusions

En edificis docents tals com el Rectorat hi ha una correlació a priori evident entre nombre de connexions a la xarxa Wi-Fi i consum energètic de l'edifici, la qual cosa significa que és molt probable que també hi hagi una correlació entre l'ocupació real de l'edifici i el nombre de connexions a la xarxa (que, cal tenir-ho en compte, es pretén usar com a mesura indirecta del primer); seria necessari un altre estudi per determinar a ciència certa si això és realment així. No es pot modelar el comportament dels dos parells de dades linealment de manera acurada, possiblement degut a la gran quantitat d'hores amb ocupació mínima i consum ancorat en valors de vora el 25% del màxim.

Tot i així, en edificis d'aquest tipus es poden aplicar mesures de reducció del consum energètic basades en la informació obtinguda dels punts d'accés a Internet Wi-Fi.

D'altra banda l'edifici CREA, especialitzat en recerca i amb diversos laboratoris, no és gaire idoni per a l'aplicació d'aquest tipus de mesures degut als següents factors:

1. Presenta errors a les lectures de consum elèctric.
2. El consum elèctric està poc correlacionat amb el nombre de dispositius connectats a la xarxa Wi-Fi.
3. La baixa ocupació i el menor nombre de connexions a la xarxa proveeixen dades estadísticament menys sòlides.
4. Conté maquinària i aparells de laboratori que poden requerir molta potència elèctrica tot i que només hi hagi una persona usant-los, i és possible que algunes d'aquestes màquines s'hagin de deixar enceses durant llargs períodes de temps.

Per a l'edifici del Rectorat, la correlació i el model lineal que se'n desprèn han mostrat ser quasi idèntics tant a l'anàlisi per a tots els dies del període com només pels dies d'obertura al públic. Hi ha una millora marginal en el primer cas.

Per a l'edifici CREA, d'altra banda, la millora és significativa quan s'ometen els dies de tancament al públic i els dies sospitosos de contenir errors a les lectures de consum elèctric. Tot i així, la correlació obtinguda segueix sent notablement més dèbil que per a l'altre edifici analitzat i el model també és pitjor.

10. Propostes de millora

En base a l'anàlisi realitzada

- Si hi ha pocs dispositius connectats, de l'ordre de la quantitat usual quan l'edifici és tancat i addicionalment és dia festiu, cap de setmana o l'edifici està tancat per qualsevol altre motiu, forçar l'apagat de tots els sistemes: climatització, enllumenat, ordinadors, etc. Si després d'això algú

requereix encendre'n algun un altre cop, no tornar a tancar automàticament fins al següent cicle. Aquesta mesura requeriria poca inversió inicial i és completament automatitzable. Té el potencial de reduir l'elevat consum *fantasma* dels edificis, tot i que és complicat de saber-ne l'abast sense conèixer els motius d'aquest consum: reduint en un 20% el consum en horari nocturn només de l'edifici del Rectorat, la Universitat estalviaria uns **74.500 kWh anuals**, que suposant 0,65 kg de diòxid de carboni per kWh implicaria **48,4 tones de CO₂ cada any** i, suposant un preu constant de 0,13 €/kWh es podrien estalviar **anualment 9.680 €**. Cal tenir en compte que en aquest edifici s'hi ubica un servidor informàtic, del que se'n deu desprendre una part molt significativa d'aquest consum i que no s'atura en cap hora del dia.

- En sales d'ordinadors, biblioteques i altres edificis o sales amb ordinadors, mantenir tancats els ordinadors en funció del número d'ocupants previst. Per poder dur a terme amb garanties aquesta proposta és necessari que la informació d'ocupació del(s) punts d'accés Wi-Fi tingui una resolució espacial suficientment alta en el cas de les sales amb ordinadors i que el nombre d'ocupants presenti una correlació clara amb el de dispositius connectats. Per aquests motius seria més fàcil aplicar-la a edificis sencers tals com biblioteques que a sales petites. Estimant un consum de 60 W per un ordinador encès però en repòs, si es mantingués apagat 5 hores al dia durant 200 dies d'obertura al públic d'un edifici qualsevol amb 35 ordinadors, es podrien estalviar uns **2.100 kWh** cada any; amb les mateixes suposicions que en el punt anterior això suposaria una reducció de **1,37 t de CO₂** i un estalvi econòmic de **273 €**.
- En cas de tenir molt bona resolució espacial (possibilitat de determinar acuradament l'ocupació en espais concrets), automàticament engegar il·luminació a les zones previsiblement ocupades de l'espai o sala (per exemple primeres files en una classe a mig omplir). Es pot combinar i potenciar amb informació meteorològica (no obrir llums automàticament si fa un dia assolellat) i amb la flexibilitat i eficiència que ofereix l'enllumenat LED. Actualment la resolució espacial, amb l'excepció

d'edificis singulars tals com l'auditori de Cappont, no és suficient per a dur a terme aquesta mesura i seria necessari l'ús de mètodes més precisos per a determinar l'ocupació de cada sala tals com sensors de pas amb fotocèl·lules.

11. Agraïments

M'agradaria agraïr per la seva generosa contribució:

A Marc Medrano Martorell i Jordi Cipriano Líndez, pel bon guiatge i permetre'm treballar i organitzar la feina de la manera que em resultés més còmoda.

A Josep Maria Martí i Puigvert, pel recolzament desinteressat i l'ajuda en la iniciació a l'R, així com la cessió de les dades de consum elèctric.

A Gerard Mor, del grup d'investigació CIMNE, pel suport tècnic i assessorament en estadística i programació en R.

12. Referències bibliogràfiques i bibliografia consultada

Balaji, Bharathan, Jian Xu, Anthony Nwokafor, Yuvraj Agarwal, i Rajesh Gupta. «Occupancy Based HVAC Actuation using Existing WiFi Infrastructure within Commercial Buildings.» *Sentinel*, 2013: 14.

Christensen, Ken, Ryen Melfi, Bruce Nordman, Ben Rosenblum, i Raul Viera. «Using existing network infrastructure to estimate building occupancy and control plugged-in devices in user workspaces.» *Communication Networks and Distributed Systems*, 2014: 4.

Columbia University. *The Climate System*. 2007.
<http://eesc.columbia.edu/courses/ees/climate/lectures/radiation/> (últim accés: 6 / 2017).

European Comission. *Climate Action*. 2017.
https://ec.europa.eu/clima/change/consequences_en (últim accés: 6 / 2017).

Govern de Bangla Desh. *Government of the People's Republic of Bangladesh*. 2008.
<https://web.archive.org/web/20091007060017/http://www.moef.gov.bd/moef.pdf> (últim accés: 2017).

Labeodan, Timilehin, Wim Zeiler, Gert Boxem, i Yang Zhao. «Occupancy measurement in commercial office buildings for demand-driven control applications - A survey and detection system evaluation.» *Energy and Buildings*, 2015: 303.

Li, Du, Bharathan Balaji, Yifei Jiang, i Kshitiz Singh. *A Wi-Fi Based Occupancy Sensing Approach to Smart Energy in Commercial Office Buildings*. Toronto: Buildsys, 2012, 2.

Martani, Claudio, David Lee, Prudence Robinson, Rex Britter, i Carlo Ratti. «ENERNET: Studying the dynamic relationship between building occupancy and energy consumption.» *Energy and Buildings*, 2012: 584.

Medrano Martorell, Marc. "Presentation - Instal·lacions I, curs 2015-16." Lleida: Universitat de Lleida, 2014. 15.

Melffi, Ryan, Ben Rosenblum, Bruce Nordman, and Ken Christensen. "Measuring Building Occupancy Using Existing Network Infrastructure." 2011.

NOAA/Scripps Institution of Oceanography. *NASA Climate*. 9 / 5 / 2013.
<https://climate.nasa.gov/news/916/for-first-time-earths-single-day-co2-tops-400-ppm/> (últim accés: 6 / 2017).

Richardson, Ian, Murray Thomson, i David Infield. «A high-resolution domestic building occupancy model for energy demand simulations.» *Energy and Buildings*, 2008: 1560.

Tverberg, Gail. *Our Finite World*. 12 / 3 / 2012.
<https://ourfiniteworld.com/2012/03/12/world-energy-consumption-since-1820-in-charts/> (últim accés: 6 / 2017).

World Bank. *The World Bank*. 2014.
http://data.worldbank.org/indicator/EG.USE.ELEC.KH.PC?view=chart&year_high_desc=true.

Annex – Codi R emprat

INICIALITZACIÓ

```
```{r}
```

#INICIALITZACIÓ

#Neteja de variables

```
rm(list=ls())
```

# Càrrega de la llibreria data.table

```
library(data.table)
```

```
```
```

IMPORTACIÓ I CREACIÓ DEL DATAFRAME DE DADES

```
```{r}
```

#IMPORTACIÓ I CREACIÓ DEL DATAFRAME DE DADES

# Escollim llegir el fitxer mitjançant la funció fread

```
df <- fread(input="output Zabbix.csv",sep=",",colClasses =
"character",data.table=F,header=T)
```

#eliminar columna itemid

```
df$itemid <- NULL
```

```
```
```

CREACIÓ DE DATAFRAMES PER A CADA EDIFICI

```
```{r}
```

#CREACIÓ DE DATAFRAMES PER A CADA EDIFICI

```

#Dataframe edifici RECTORAT

df.RECTORAT.RECTORAT <- df[grepl("AR", df$itemname),]

#Supressió columna itemname

df.RECTORAT.RECTORAT <- df.RECTORAT.RECTORAT[,-2]

#Conversió dels valors de la columna value a numèrics

df.RECTORAT.RECTORAT[,2] <- as.numeric(df.RECTORAT.RECTORAT[,2])

#Agregació dels valors de temps a hores senceres

df.RECTORAT.RECTORAT
<-
aggregate(as.numeric((df.RECTORAT.RECTORAT[,2])),list(substr((df.RECTORAT.RECTORAT[,1]),1,13)),sum,na.omit=NULL)

df.RECTORAT.RECTORAT$Group.1 <- as.POSIXct(df.RECTORAT.RECTORAT$Group.1, "%Y-%m-%d %H",tz="utc")

#Dataframe edifici A ETSEA

df.ETSEA.A <- df[grepl("BRP", df$itemname),]

#Supressió columna itemname

df.ETSEA.A <- df.ETSEA.A[,-2]

#Conversió dels valors de la columna value a numèrics

df.ETSEA.A[,2] <- as.numeric(df.ETSEA.A[,2])

#Agregació dels valors de temps a hores senceres

df.ETSEA.A
<-
aggregate(as.numeric((df.ETSEA.A[,2])),list(substr((df.ETSEA.A[,1]),1,13)),sum,na.omit=NULL)

df.ETSEA.A$Group.1 <- as.POSIXct(df.ETSEA.A$Group.1, "%Y-%m-%d %H",tz="utc")

#Dataframe edifici B ETSEA

df.ETSEA.B <- df[grepl("BRB", df$itemname),]

```

```

#Supressió columna itemname

df.ETSEA.B <- df.ETSEA.B[, -2]

#Conversió dels valors de la columna value a numèrics

df.ETSEA.B[, 2] <- as.numeric(df.ETSEA.B[, 2])

#Agregació dels valors de temps a hores senceres

df.ETSEA.B
aggregate(as.numeric((df.ETSEA.B[, 2])), list(substr((df.ETSEA.B[, 1]), 1, 13)), sum, na.o
mit=NULL)

df.ETSEA.B$Group.1 <- as.POSIXct(df.ETSEA.B$Group.1, "%Y-%m-%d %H", tz="utc")

#Dataframe edifici C ETSEA

df.ETSEA.C <- df[grep("BRC", df$itemname),]

#Supressió columna itemname

df.ETSEA.C <- df.ETSEA.C[, -2]

#Conversió dels valors de la columna value a numèrics

df.ETSEA.C[, 2] <- as.numeric(df.ETSEA.C[, 2])

#Agregació dels valors de temps a hores senceres

df.ETSEA.C
aggregate(as.numeric((df.ETSEA.C[, 2])), list(substr((df.ETSEA.C[, 1]), 1, 13)), sum, na.o
mit=NULL)

df.ETSEA.C$Group.1 <- as.POSIXct(df.ETSEA.C$Group.1, "%Y-%m-%d %H", tz="utc")

#Dataframe edifici 1 ETSEA

df.ETSEA.1 <- df[grep("BR1", df$itemname),]

#Supressió columna itemname

df.ETSEA.1 <- df.ETSEA.1[, -2]

#Conversió dels valors de la columna value a numèrics

```

```

df.ETSEA.1[,2] <- as.numeric(df.ETSEA.1[,2])

#Agregació dels valors de temps a hores senceres

df.ETSEA.1 <- aggregate(as.numeric((df.ETSEA.1[,2])),list(substr((df.ETSEA.1[,1]),1,13)),sum,na.omit=NULL)

df.ETSEA.1$Group.1 <- as.POSIXct(df.ETSEA.1$Group.1,"%Y-%m-%d %H",tz="utc")

#Dataframe edifici 2 ETSEA

df.ETSEA.2 <- df[grep("BR2", df$itemname),]

#Supressió columna itemname

df.ETSEA.2 <- df.ETSEA.2[,-2]

#Conversió dels valors de la columna value a numèrics

df.ETSEA.2[,2] <- as.numeric(df.ETSEA.2[,2])

#Agregació dels valors de temps a hores senceres

df.ETSEA.2 <- aggregate(as.numeric((df.ETSEA.2[,2])),list(substr((df.ETSEA.2[,1]),1,13)),sum,na.omit=NULL)

df.ETSEA.2$Group.1 <- as.POSIXct(df.ETSEA.2$Group.1,"%Y-%m-%d %H",tz="utc")

#Dataframe edifici 3 ETSEA

df.ETSEA.3 <- df[grep("BR3", df$itemname),]

#Supressió columna itemname

df.ETSEA.3 <- df.ETSEA.3[,-2]

#Conversió dels valors de la columna value a numèrics

df.ETSEA.3[,2] <- as.numeric(df.ETSEA.3[,2])

#Agregació dels valors de temps a hores senceres

```

```

df.ETSEA.3 <-
aggregate(as.numeric((df.ETSEA.3[,2])),list(substr((df.ETSEA.3[,1]),1,13)),sum,na.o
mit=NULL)

df.ETSEA.3$Group.1 <- as.POSIXct(df.ETSEA.3$Group.1,"%Y-%m-%d %H",tz="utc")

#Dataframe edifici 4 ETSEA

df.ETSEA.4 <- df[grep("BR4", df$itemname),]

#Supressió columna itemname

df.ETSEA.4 <- df.ETSEA.4[,-2]

#Conversió dels valors de la columna value a numèrics

df.ETSEA.4[,2] <- as.numeric(df.ETSEA.4[,2])

#Agregació dels valors de temps a hores senceres

df.ETSEA.4 <-
aggregate(as.numeric((df.ETSEA.4[,2])),list(substr((df.ETSEA.4[,1]),1,13)),sum,na.o
mit=NULL)

df.ETSEA.4$Group.1 <- as.POSIXct(df.ETSEA.4$Group.1,"%Y-%m-%d %H",tz="utc")

#Dataframe edifici 5 ETSEA

df.ETSEA.5 <- df[grep("BR5-", df$itemname),]

#Supressió columna itemname

df.ETSEA.5 <- df.ETSEA.5[,-2]

#Conversió dels valors de la columna value a numèrics

df.ETSEA.5[,2] <- as.numeric(df.ETSEA.5[,2])

#Agregació dels valors de temps a hores senceres

df.ETSEA.5 <-
aggregate(as.numeric((df.ETSEA.5[,2])),list(substr((df.ETSEA.5[,1]),1,13)),sum,na.o
mit=NULL)

```

```

df.ETSEA.5$Group.1 <- as.POSIXct(df.ETSEA.5$Group.1, "%Y-%m-%d %H", tz="utc")

#Dataframe edifici 5B ETSEA

df.ETSEA.5B <- df[grep("BR5B", df$itemname),]

#Supressió columna itemname

df.ETSEA.5B <- df.ETSEA.5B[,-2]

#Conversió dels valors de la columna value a numèrics

df.ETSEA.5B[,2] <- as.numeric(df.ETSEA.5B[,2])

#Agregació dels valors de temps a hores senceres

df.ETSEA.5B <- aggregate(as.numeric((df.ETSEA.5B[,2])), list(substr((df.ETSEA.5B[,1]), 1, 13)), sum, na.
.omit=NULL)

df.ETSEA.5B$Group.1 <- as.POSIXct(df.ETSEA.5B$Group.1, "%Y-%m-%d %H", tz="utc")

#Dataframe edifici 6 ETSEA

df.ETSEA.6 <- df[grep("BR6", df$itemname),]

#Supressió columna itemname

df.ETSEA.6 <- df.ETSEA.6[,-2]

#Conversió dels valors de la columna value a numèrics

df.ETSEA.6[,2] <- as.numeric(df.ETSEA.6[,2])

#Agregació dels valors de temps a hores senceres

df.ETSEA.6 <- aggregate(as.numeric((df.ETSEA.6[,2])), list(substr((df.ETSEA.6[,1]), 1, 13)), sum, na.
omit=NULL)

df.ETSEA.6$Group.1 <- as.POSIXct(df.ETSEA.6$Group.1, "%Y-%m-%d %H", tz="utc")

#Dataframe edifici FIF CCS

```



```

df.CCS.FIF <- df[grepl("DR1", df$itemname),]

#Supressió columna itemname

df.CCS.FIF <- df.CCS.FIF[,-2]

#Conversió dels valors de la columna value a numèrics

df.CCS.FIF[,2] <- as.numeric(df.CCS.FIF[,2])

#Agregació dels valors de temps a hores senceres

df.CCS.FIF
 <-
aggregate(as.numeric((df.CCS.FIF[,2])),list(substr((df.CCS.FIF[,1]),1,13)),sum,na.o
mit=NULL)

df.CCS.FIF$Group.1 <- as.POSIXct(df.CCS.FIF$Group.1,"%Y-%m-%d %H",tz="utc")

#Dataframe edifici FMED CCS

df.CCS.FMED <- df[grepl("DRP", df$itemname),]

#Supressió columna itemname

df.CCS.FMED <- df.CCS.FMED[,-2]

#Conversió dels valors de la columna value a numèrics

df.CCS.FMED[,2] <- as.numeric(df.CCS.FMED[,2])

#Agregació dels valors de temps a hores senceres

df.CCS.FMED
 <-
aggregate(as.numeric((df.CCS.FMED[,2])),list(substr((df.CCS.FMED[,1]),1,13)),sum,na
.omit=NULL)

df.CCS.FMED$Group.1 <- as.POSIXct(df.CCS.FMED$Group.1,"%Y-%m-%d %H",tz="utc")

#Dataframe edifici ANNEX CCS

df.CCS.ANNEX <- df[grepl("ER1", df$itemname),]

#Supressió columna itemname

df.CCS.ANNEX <- df.CCS.ANNEX[,-2]

```

```

#Conversió dels valors de la columna value a numèrics

df.CCS.ANNEX[,2] <- as.numeric(df.CCS.ANNEX[,2])

#Agregació dels valors de temps a hores senceres

df.CCS.ANNEX <-
aggregate(as.numeric((df.CCS.ANNEX[,2])),list(substr((df.CCS.ANNEX[,1]),1,13)),sum,
na.omit=NULL)

df.CCS.ANNEX$Group.1 <- as.POSIXct(df.CCS.ANNEX$Group.1,"%Y-%m-%d %H",tz="utc")

#Dataframe edifici BIOMEDICINA CCS

df.CCS.BIOMEDICINA <- df[grep("ER2", df$itemname),]

#Supressió columna itemname

df.CCS.BIOMEDICINA <- df.CCS.BIOMEDICINA[,-2]

#Conversió dels valors de la columna value a numèrics

df.CCS.BIOMEDICINA[,2] <- as.numeric(df.CCS.BIOMEDICINA[,2])

#Agregació dels valors de temps a hores senceres

df.CCS.BIOMEDICINA <-
aggregate(as.numeric((df.CCS.BIOMEDICINA[,2])),list(substr((df.CCS.BIOMEDICINA[,1])
,1,13)),sum,na.omit=NULL)

df.CCS.BIOMEDICINA$Group.1 <- as.POSIXct(df.CCS.BIOMEDICINA$Group.1,"%Y-%m-%d
%H",tz="utc")

#Dataframe edifici VELL CCS

df.CCS.VELL <- df[grep("ERP", df$itemname),]

#Supressió columna itemname

df.CCS.VELL <- df.CCS.VELL[,-2]

#Conversió dels valors de la columna value a numèrics

df.CCS.VELL[,2] <- as.numeric(df.CCS.VELL[,2])

```

```

#Agregaci ó dels valors de temps a hores senceres

df.CCS.VELL <-
aggregate(as.numeric((df.CCS.VELL[,2])),list(substr((df.CCS.VELL[,1]),1,13)),sum,na
.omit=NULL)

df.CCS.VELL$Group.1 <- as.POSIXct(df.CCS.VELL$Group.1,"%Y-%m-%d %H",tz="utc")

#Dataframe edifici EPS CAPPONT

df.CAPPONT.EPS <- df[grepl("FRP|FR1", df$itemname),]

#Supressi ó columna itemname

df.CAPPONT.EPS <- df.CAPPONT.EPS[,-2]

#Conversi ó dels valors de la columna value a num è rics

df.CAPPONT.EPS[,2] <- as.numeric(df.CAPPONT.EPS[,2])

#Agregaci ó dels valors de temps a hores senceres

df.CAPPONT.EPS <-
aggregate(as.numeric((df.CAPPONT.EPS[,2])),list(substr((df.CAPPONT.EPS[,1]),1,13)),
sum,na.omit=NULL)

df.CAPPONT.EPS$Group.1 <- as.POSIXct(df.CAPPONT.EPS$Group.1,"%Y-%m-%d %H",tz="utc")

#Dataframe edifici AULARI CAPPONT

df.CAPPONT.AULARI <- df[grepl("FR2", df$itemname),]

#Supressi ó columna itemname

df.CAPPONT.AULARI <- df.CAPPONT.AULARI[,-2]

#Conversi ó dels valors de la columna value a num è rics

df.CAPPONT.AULARI[,2] <- as.numeric(df.CAPPONT.AULARI[,2])

#Agregaci ó dels valors de temps a hores senceres

```

```

df.CAPPONT.AULARI <-
aggregate(as.numeric((df.CAPPONT.AULARI[,2])),list(substr((df.CAPPONT.AULARI[,1]),1
,13)),sum,na.omit=NULL)

df.CAPPONT.AULARI$Group.1 <- as.POSIXct(df.CAPPONT.AULARI$Group.1, "%Y-%m-%d
%H",tz="utc")

#Dataframe edifici FDET CAPPONT

df.CAPPONT.FDET <- df[grep("FR3", df$itemname),]

#Supressió columna itemname

df.CAPPONT.FDET <- df.CAPPONT.FDET[,-2]

#Conversió dels valors de la columna value a numèrics

df.CAPPONT.FDET[,2] <- as.numeric(df.CAPPONT.FDET[,2])

#Agregació dels valors de temps a hores senceres

df.CAPPONT.FDET <-
aggregate(as.numeric((df.CAPPONT.FDET[,2])),list(substr((df.CAPPONT.FDET[,1]),1,13)
),sum,na.omit=NULL)

df.CAPPONT.FDET$Group.1 <- as.POSIXct(df.CAPPONT.FDET$Group.1, "%Y-%m-%d
%H",tz="utc")

#Dataframe edifici CREA CAPPONT

df.CAPPONT.CREA <- df[grep("FR4", df$itemname),]

#Supressió columna itemname

df.CAPPONT.CREA <- df.CAPPONT.CREA[,-2]

#Conversió dels valors de la columna value a numèrics

df.CAPPONT.CREA[,2] <- as.numeric(df.CAPPONT.CREA[,2])

#Agregació dels valors de temps a hores senceres

```

```

df.CAPPONT.CREA <-
aggregate(as.numeric((df.CAPPONT.CREA[,2])),list(substr((df.CAPPONT.CREA[,1]),1,13)
),sum,na.omit=NULL)

df.CAPPONT.CREA$Group.1 <- as.POSIXct(df.CAPPONT.CREA$Group.1,"%Y-%m-%d
%H",tz="utc")

#Dataframe edifici FEPTS CAPPONT

df.CAPPONT.FEPTS <- df[grep("FR5", df$itemname),]

#Supressió columna itemname

df.CAPPONT.FEPTS <- df.CAPPONT.FEPTS[,-2]

#Conversió dels valors de la columna value a numèrics

df.CAPPONT.FEPTS[,2] <- as.numeric(df.CAPPONT.FEPTS[,2])

#Agregació dels valors de temps a hores senceres

df.CAPPONT.FEPTS <-
aggregate(as.numeric((df.CAPPONT.FEPTS[,2])),list(substr((df.CAPPONT.FEPTS[,1]),1,1
3)),sum,na.omit=NULL)

df.CAPPONT.FEPTS$Group.1 <- as.POSIXct(df.CAPPONT.FEPTS$Group.1,"%Y-%m-%d
%H",tz="utc")

#Dataframe edificis CCCT, AUDITORI i ANNEX CAPPONT

df.CAPPONT.CCCT <- df[grep("FRE", df$itemname),]

#Supressió columna itemname

df.CAPPONT.CCCT <- df.CAPPONT.CCCT[,-2]

#Conversió dels valors de la columna value a numèrics

df.CAPPONT.CCCT[,2] <- as.numeric(df.CAPPONT.CCCT[,2])

#Agregació dels valors de temps a hores senceres

```

```

df.CAPPONT.CCCT <-
aggregate(as.numeric(df.CAPPONT.CCCT[,2]),list(substr(df.CAPPONT.CCCT[,1],1,13)
),sum,na.omit=NULL)

df.CAPPONT.CCCT$Group.1 <- as.POSIXct(df.CAPPONT.CCCT$Group.1,"%Y-%m-%d
%H",tz="utc")

#df.CCS.ANNEX = df.CCS.ANNEX[,-2]

#df.CCS.ANNEX[,2]=as.numeric(df.CCS.ANNEX[,2])

#a=aggregate(as.numeric(df.CCS.ANNEX[,2]),list(substr(df.CCS.ANNEX[,1],1,13)),sum,n
a.omit=NULL)

#a$Group.1=as.POSIXct(a$Group.1,"%Y-%m-%d %H",tz="utc")
```

```

IMPORTACIÓ I CREACIÓ DELS DATAFRAMES DE CONSUM

```
```{r}
```

## #IMPORTACIÓ I CREACIÓ DELS DATAFRAMES DE CONSUM

```
#Dataframe edifici RECTORAT
```

```
df.RECTORAT.RECTORAT.CONSUM <- fread(input="C:/Users/i/Desktop/_TFG/Arxius
R/Consums/RECTORAT.RECTORAT.csv",sep=";",colClasses =
"character",data.table=F,header=F)
```

```
#Supressió columna ID
```

```
df.RECTORAT.RECTORAT.CONSUM <- df.RECTORAT.RECTORAT.CONSUM[,-1]
```

```
#Variables data i hora juntes a la columna V2
```

```

df. RECTORAT. RECTORAT. CONSUM$V2 <- with(df. RECTORAT. RECTORAT. CONSUM,
as. POSIXct(paste(as. Date(V2, format="%d/%m/%Y"), V3)))

#Supressió columna time

df. RECTORAT. RECTORAT. CONSUM <- df. RECTORAT. RECTORAT. CONSUM[,-2]

#Separador decimal del consum de coma a punt

df. RECTORAT. RECTORAT. CONSUM$V4 <- gsub("\\\\", " ", df. RECTORAT. RECTORAT. CONSUM$V4)

#Consum a número

df. RECTORAT. RECTORAT. CONSUM$V4 <- <-
as. numeric(as. character(df. RECTORAT. RECTORAT. CONSUM$V4))

#Dataframe edifici A ETSEA

df. ETSEA. A. CONSUM <- fread(input="C:/Users/i/Desktop/_TFG/Arxius
R/Consums/ETSEA. A. csv", sep=";", colClasses = "character", data.table=F, header=F)

#Supressió columna ID

df. ETSEA. A. CONSUM <- df. ETSEA. A. CONSUM[,-1]

#Variables data i hora juntes a la columna V2

df. ETSEA. A. CONSUM$V2 <- with(df. ETSEA. A. CONSUM, as. POSIXct(paste(as. Date(V2,
format="%d/%m/%Y"), V3)))

#Supressió columna time

df. ETSEA. A. CONSUM <- df. ETSEA. A. CONSUM[,-2]

#Separador decimal del consum de coma a punt

df. ETSEA. A. CONSUM$V4 <- gsub("\\\\", " ", df. ETSEA. A. CONSUM$V4)

#Consum a número

df. ETSEA. A. CONSUM$V4 <- as. numeric(as. character(df. ETSEA. A. CONSUM$V4))

#Dataframe edifici B ETSEA

#(SENSE DADES)

```

```

#Dataframe edifici C ETSEA

#(SENSE DADES)

#Dataframe edifici 1 ETSEA

df.ETSEA.1.CONSUM <- fread(input="C:/Users/i/Desktop/_TFG/Arxiu
R/Consums/ETSEA.1.csv",sep=";",colClasses = "character",data.table=F,header=F)

#Supressió columna ID

df.ETSEA.1.CONSUM <- df.ETSEA.1.CONSUM[,-1]

#Variables data i hora juntes a la columna V2

df.ETSEA.1.CONSUM$V2 <- with(df.ETSEA.1.CONSUM, as.POSIXct(paste(as.Date(V2,
format="%d/%m/%Y"), V3)))

#Supressió columna time

df.ETSEA.1.CONSUM <- df.ETSEA.1.CONSUM[,-2]

#Separador decimal del consum de coma a punt

df.ETSEA.1.CONSUM$V4 <- gsub("\\\\",",", ". ", df.ETSEA.1.CONSUM$V4)

#Consum a número

df.ETSEA.1.CONSUM$V4 <- as.numeric(as.character(df.ETSEA.1.CONSUM$V4))

#Dataframe edifici 2 ETSEA

df.ETSEA.2.CONSUM <- fread(input="C:/Users/i/Desktop/_TFG/Arxiu
R/Consums/ETSEA.2.csv",sep=";",colClasses = "character",data.table=F,header=F)

#Supressió columna ID

df.ETSEA.2.CONSUM <- df.ETSEA.2.CONSUM[,-1]

#Variables data i hora juntes a la columna V2

df.ETSEA.2.CONSUM$V2 <- with(df.ETSEA.2.CONSUM, as.POSIXct(paste(as.Date(V2,
format="%d/%m/%Y"), V3)))

```



```

#Supressió columna time

df.ETSEA.2.CONSUM <- df.ETSEA.2.CONSUM[,-2]

#Separador decimal del consum de coma a punt

df.ETSEA.2.CONSUM$V4 <- gsub("\\\\",",", ".", df.ETSEA.2.CONSUM$V4)

#Consum a número

df.ETSEA.2.CONSUM$V4 <- as.numeric(as.character(df.ETSEA.2.CONSUM$V4))

#Dataframe edifici 3 ETSEA

df.ETSEA.3.CONSUM <- fread(input="C:/Users/i/Desktop/_TFG/Arxius
R/Consums/ETSEA.3.csv", sep=";", colClasses = "character", data.table=F, header=F)

#Supressió columna ID

df.ETSEA.3.CONSUM <- df.ETSEA.3.CONSUM[,-1]

#Variables data i hora juntes a la columna V2

df.ETSEA.3.CONSUM$V2 <- with(df.ETSEA.3.CONSUM, as.POSIXct(paste(as.Date(V2,
format="%d/%m/%Y"), V3)))

#Supressió columna time

df.ETSEA.3.CONSUM <- df.ETSEA.3.CONSUM[,-2]

#Separador decimal del consum de coma a punt

df.ETSEA.3.CONSUM$V4 <- gsub("\\\\",",", ".", df.ETSEA.3.CONSUM$V4)

#Consum a número

df.ETSEA.3.CONSUM$V4 <- as.numeric(as.character(df.ETSEA.3.CONSUM$V4))

#Dataframe edifici 4 ETSEA

df.ETSEA.4.CONSUM <- fread(input="C:/Users/i/Desktop/_TFG/Arxius
R/Consums/ETSEA.4.csv", sep=";", colClasses = "character", data.table=F, header=F)

#Supressió columna ID

```

```

df.ETSEA.4.CONSUM <- df.ETSEA.4.CONSUM[,-1]

#Variables data i hora juntes a la columna V2

df.ETSEA.4.CONSUM$V2 <- with(df.ETSEA.4.CONSUM, as.POSIXct(paste(as.Date(V2,
format="%d/%m/%Y"), V3)))

#Supressió columna time

df.ETSEA.4.CONSUM <- df.ETSEA.4.CONSUM[,-2]

#Separador decimal del consum de coma a punt

df.ETSEA.4.CONSUM$V4 <- gsub("\\\\", " . ", df.ETSEA.4.CONSUM$V4)

#Consum a número

df.ETSEA.4.CONSUM$V4 <- as.numeric(as.character(df.ETSEA.4.CONSUM$V4))

#Dataframe edifici 5 ETSEA

df.ETSEA.5.CONSUM <- fread(input="C:/Users/i/Desktop/_TFG/Arxius
R/Consums/ETSEA.5.csv", sep=";", colClasses = "character", data.table=F, header=F)

#Supressió columna ID

df.ETSEA.5.CONSUM <- df.ETSEA.5.CONSUM[,-1]

#Variables data i hora juntes a la columna V2

df.ETSEA.5.CONSUM$V2 <- with(df.ETSEA.5.CONSUM, as.POSIXct(paste(as.Date(V2,
format="%d/%m/%Y"), V3)))

#Supressió columna time

df.ETSEA.5.CONSUM <- df.ETSEA.5.CONSUM[,-2]

#Separador decimal del consum de coma a punt

df.ETSEA.5.CONSUM$V4 <- gsub("\\\\", " . ", df.ETSEA.5.CONSUM$V4)

#Consum a número

df.ETSEA.5.CONSUM$V4 <- as.numeric(as.character(df.ETSEA.5.CONSUM$V4))

```

```

#Dataframe edifici 5B ETSEA

df.ETSEA.5B.CONSUM <- fread(input="C:/Users/i/Desktop/_TFG/Arxiu
R/Consums/ETSEA.5B.csv",sep=";",colClasses = "character",data.table=F,header=F)

#Supressió columna ID

df.ETSEA.5B.CONSUM <- df.ETSEA.5B.CONSUM[,-1]

#Variables data i hora juntes a la columna V2

df.ETSEA.5B.CONSUM$V2 <- with(df.ETSEA.5B.CONSUM, as.POSIXct(paste(as.Date(V2,
format="%d/%m/%Y"), V3)))

#Supressió columna time

df.ETSEA.5B.CONSUM <- df.ETSEA.5B.CONSUM[,-2]

#Separador decimal del consum de coma a punt

df.ETSEA.5B.CONSUM$V4 <- gsub("\\\\", ".", df.ETSEA.5B.CONSUM$V4)

#Consum a número

df.ETSEA.5B.CONSUM$V4 <- as.numeric(as.character(df.ETSEA.5B.CONSUM$V4))

#Dataframe edifici 6 ETSEA

df.ETSEA.6.CONSUM <- fread(input="C:/Users/i/Desktop/_TFG/Arxiu
R/Consums/ETSEA.6.csv",sep=";",colClasses = "character",data.table=F,header=F)

#Supressió columna ID

df.ETSEA.6.CONSUM <- df.ETSEA.6.CONSUM[,-1]

#Variables data i hora juntes a la columna V2

df.ETSEA.6.CONSUM$V2 <- with(df.ETSEA.6.CONSUM, as.POSIXct(paste(as.Date(V2,
format="%d/%m/%Y"), V3)))

#Supressió columna time

df.ETSEA.6.CONSUM <- df.ETSEA.6.CONSUM[,-2]

#Separador decimal del consum de coma a punt

df.ETSEA.6.CONSUM$V4 <- gsub("\\\\", ".", df.ETSEA.6.CONSUM$V4)

```

```

#Consum a número

df.ETSEA.6.CONSUM$V4 <- as.numeric(as.character(df.ETSEA.6.CONSUM$V4))

#Dataframe edifici FIF CCS

df.CCS.FIF.CONSUM <- fread(input="C:/Users/i/Desktop/_TFG/Arxius
R/Consums/CCS.FIF.csv", sep=";", colClasses = "character", data.table=F, header=F)

#Supressió columna ID

df.CCS.FIF.CONSUM <- df.CCS.FIF.CONSUM[, -1]

#Variables data i hora juntes a la columna V2

df.CCS.FIF.CONSUM$V2 <- with(df.CCS.FIF.CONSUM, as.POSIXct(paste(as.Date(V2,
format="%d/%m/%Y"), V3)))

#Supressió columna time

df.CCS.FIF.CONSUM <- df.CCS.FIF.CONSUM[, -2]

#Separador decimal del consum de coma a punt

df.CCS.FIF.CONSUM$V4 <- gsub("\\\\", ".", df.CCS.FIF.CONSUM$V4)

#Consum a número

df.CCS.FIF.CONSUM$V4 <- as.numeric(as.character(df.CCS.FIF.CONSUM$V4))

#Dataframe edifici FMED CCS

df.CCS.FMED.CONSUM <- fread(input="C:/Users/i/Desktop/_TFG/Arxius
R/Consums/CCS.FMED.csv", sep=";", colClasses = "character", data.table=F, header=F)

#Supressió columna ID

df.CCS.FMED.CONSUM <- df.CCS.FMED.CONSUM[, -1]

#Variables data i hora juntes a la columna V2

df.CCS.FMED.CONSUM$V2 <- with(df.CCS.FMED.CONSUM, as.POSIXct(paste(as.Date(V2,
format="%d/%m/%Y"), V3)))

#Supressió columna time

```

```

df.CCS.FMED.CONSUM <- df.CCS.FMED.CONSUM[,-2]

#Separador decimal del consum de coma a punt

df.CCS.FMED.CONSUM$V4 <- gsub("\\\\", "\\. ", df.CCS.FMED.CONSUM$V4)

#Consum a número

df.CCS.FMED.CONSUM$V4 <- as.numeric(as.character(df.CCS.FMED.CONSUM$V4))

#Dataframe edifici ANNEX CCS

#(SENSE DADES)

#Dataframe edifici BIOMEDICINA CCS

#(2 EDIFICIS EN LECTURES DE CONSUM, 1 EDIFICI EN LECTURES WI-FI)

#Dataframe edifici VELL CCS

#(SENSE DADES, PODRIA SER L'EDIFICI DE BIOMEDICINA QUE FALTA)

#Dataframe edifici EPS CAPPONT

df.CAPPONT.EPS.CONSUM <- fread(input="C:/Users/i/Desktop/_TFG/Arxius
R/Consums/CAPPONT.EPS.csv", sep=";", colClasses = "character", data.table=F, header=F)

#Supressió columna ID

df.CAPPONT.EPS.CONSUM <- df.CAPPONT.EPS.CONSUM[,-1]

#Variables data i hora juntes a la columna V2

df.CAPPONT.EPS.CONSUM$V2 <- with(df.CAPPONT.EPS.CONSUM,
as.POSIXct(paste(as.Date(V2, format="%d/%m/%Y"), V3)))

#Supressió columna time

df.CAPPONT.EPS.CONSUM <- df.CAPPONT.EPS.CONSUM[,-2]

#Separador decimal del consum de coma a punt

```

```

df.CAPPONT.EPS.CONSUM$V4 <- gsub("\\\\", " ", df.CAPPONT.EPS.CONSUM$V4)

#Consum a número

df.CAPPONT.EPS.CONSUM$V4 <- as.numeric(as.character(df.CAPPONT.EPS.CONSUM$V4))

#Dataframe edifici AULARI CAPPONT

df.CAPPONT.AULARI.CONSUM <- fread(input="C:/Users/i/Desktop/_TFG/Arxius
R/Consums/CAPPONT.AULARI.csv", sep=";", colClasses =
"character", data.table=F, header=F)

#Supressió columna ID

df.CAPPONT.AULARI.CONSUM <- df.CAPPONT.AULARI.CONSUM[,-1]

#Variables data i hora juntes a la columna V2

df.CAPPONT.AULARI.CONSUM$V2 <- with(df.CAPPONT.AULARI.CONSUM,
as.POSIXct(paste(as.Date(V2, format="%d/%m/%Y"), V3)))

#Supressió columna time

df.CAPPONT.AULARI.CONSUM <- df.CAPPONT.AULARI.CONSUM[,-2]

#Separador decimal del consum de coma a punt

df.CAPPONT.AULARI.CONSUM$V4 <- gsub("\\\\", " ", df.CAPPONT.AULARI.CONSUM$V4)

#Consum a número

df.CAPPONT.AULARI.CONSUM$V4 <-
as.numeric(as.character(df.CAPPONT.AULARI.CONSUM$V4))

#Dataframe edifici FDET CAPPONT

df.CAPPONT.FDET.CONSUM <- fread(input="C:/Users/i/Desktop/_TFG/Arxius
R/Consums/CAPPONT.FDET.csv", sep=";", colClasses = "character", data.table=F, header=F)

#Supressió columna ID

df.CAPPONT.FDET.CONSUM <- df.CAPPONT.FDET.CONSUM[,-1]

#Variables data i hora juntes a la columna V2

```

```

df.CAPPONT.FDET.CONSUM$V2 <- with(df.CAPPONT.FDET.CONSUM,
as.POSIXct(paste(as.Date(V2, format="%d/%m/%Y"), V3)))

#Supressió columna time

df.CAPPONT.FDET.CONSUM <- df.CAPPONT.FDET.CONSUM[, -2]

#Separador decimal del consum de coma a punt

df.CAPPONT.FDET.CONSUM$V4 <- gsub("\\\\", ".", df.CAPPONT.FDET.CONSUM$V4)

#Consum a número

df.CAPPONT.FDET.CONSUM$V4 <- as.numeric(as.character(df.CAPPONT.FDET.CONSUM$V4))

#Dataframe edifici CREA CAPPONT

df.CAPPONT.CREA.CONSUM <- fread(input="C:/Users/i/Desktop/_TFG/Arxius
R/Consums/CAPPONT.CREA.csv", sep=";", colClasses = "character", data.table=F, header=F)

#Supressió columna ID

df.CAPPONT.CREA.CONSUM <- df.CAPPONT.CREA.CONSUM[, -1]

#Variables data i hora juntes a la columna V2

df.CAPPONT.CREA.CONSUM$V2 <- with(df.CAPPONT.CREA.CONSUM,
as.POSIXct(paste(as.Date(V2, format="%d/%m/%Y"), V3)))

#Supressió columna time

df.CAPPONT.CREA.CONSUM <- df.CAPPONT.CREA.CONSUM[, -2]

#Separador decimal del consum de coma a punt

df.CAPPONT.CREA.CONSUM$V4 <- gsub("\\\\", ".", df.CAPPONT.CREA.CONSUM$V4)

#Consum a número

df.CAPPONT.CREA.CONSUM$V4 <- as.numeric(as.character(df.CAPPONT.CREA.CONSUM$V4))

#Dataframe edifici FEPTS CAPPONT

```

```

df.CAPPONT.FEPTS.CONSUM <- fread(input="C:/Users/i/Desktop/_TFG/Arxiu
R/Consums/CAPPONT.FEPTS.csv",sep=";",colClasses
"character",data.table=F,header=F)

#Supressió columna ID

df.CAPPONT.FEPTS.CONSUM <- df.CAPPONT.FEPTS.CONSUM[,-1]

#Variables data i hora juntes a la columna V2

df.CAPPONT.FEPTS.CONSUM$V2 <- with(df.CAPPONT.FEPTS.CONSUM,
as.POSIXct(paste(as.Date(V2, format="%d/%m/%Y"), V3)))

#Supressió columna time

df.CAPPONT.FEPTS.CONSUM <- df.CAPPONT.FEPTS.CONSUM[,-2]

#Separador decimal del consum de coma a punt

df.CAPPONT.FEPTS.CONSUM$V4 <- gsub("\\\\,", ". ", df.CAPPONT.FEPTS.CONSUM$V4)

#Consum a número

df.CAPPONT.FEPTS.CONSUM$V4 <- as.numeric(as.character(df.CAPPONT.FEPTS.CONSUM$V4))

#Dataframe edificis CCCT, AUDITORI i ANNEX CAPPONT

#(SENSE DADES EDIFICI AUDITORI)

#IMPORTAR CONJUNTAMENT 2 CSV?

```

CONCATENACIÓ DE LES DADES WI-FI AMB EL CONSUM ENERGÈTIC

``` {r}

CONCATENACIÓ DADES WI-FI AMB CONSUM

df.RECTORAT.RECTORAT <- merge(x = df.RECTORAT.RECTORAT, y =
df.RECTORAT.RECTORAT.CONSUM, by.x = "Group.1", by.y = "V2") #HI HA UN DESFASAMENT
D'UNA HORA AL CONSUM DEL DF OBTINGUT

```



```
df.ETSEA.A <- merge(x = df.ETSEA.A, y = df.ETSEA.A.CONSUM, by.x = "Group.1", by.y =
"V2")
```

```
df.CAPPONT.CREA <- merge(x = df.CAPPONT.CREA, y = df.CAPPONT.CREA.CONSUM, by.x =
"Group.1", by.y = "V2")
```

```
...
```

GRÀFIC PER SETMANES RECTORAT

```
```{r}
```

```
#Afegir columna any
```

```
library(magrittr)
```

```
library(dplyr)
```

```
library(ggplot2)
```

```
df.RECTORAT.RECTORAT<-df.RECTORAT.RECTORAT %>%
```

```
  mutate(SetmanaAny=strftime(Group.1,"%Y-
%U"),HoraSetmana=as.numeric(strftime(Group.1,"%w"))*24+
```

```
      as.numeric(strftime(df.RECTORAT.RECTORAT$Group.1,"%H")))
```

```
#Dates inicial i final a graficar
```

```
data_ini <- as.Date("2016-11-26")
```

```
data_final <- as.Date("2016-12-31")
```

```
#Graficar les dades en múltiples gràfics agrupats segons el vector SetmanaAny
```

```
df.RECTORAT.RECTORAT %>% # using the user1 data frame
```

```
  filter(
```

```
    #Filtratge del període a traçar
```

```
    as.Date(Group.1) %>% between(data_ini,data_final)
```

```

) %>%

ggplot(aes(x =as.numeric(HoraSetmana), y =as.numeric(x))) +

  geom_line(col="darkblue") + #Gràfic del número de connexions respecte el temps

  facet_wrap(~SetmanaAny) + #Agrupar en setmanes

  labs(x = "Dies de la setmana", y = "Dispositius connectats", title = "Número de
dispositius connectats") + #Noms dels eixos

  annotate("rect", xmin =0 , xmax = 24, ymin = -Inf, ymax = Inf,   #Àrea colorejada
pels diumenges

  alpha = .2)+

  annotate("rect", xmin =144 , xmax = 168, ymin = -Inf, ymax = Inf,   #Àrea
colorejada pels dissabtes

  alpha = .1)+

  # format de les marques de l'eix de les x

  scale_x_continuous(limits=c(0,168),breaks      =      seq(0,168,24),labels      =
c("du","dl","dm","dx","dj","dv","ds",""))+

  #format del text de les marques x i dels títols dels eixos

  theme(axis.text.x=element_text(size              =13,angle              =
315),axis.title.x=element_text(size = 13),

        axis.title.y=element_text(size = 13))+

  #format del títol del gràfic

  theme(plot.title = element_text(size = 14,vjust = 1))
```


GRÀFIC COMPARATIU CONNEXIONS - CONSUM (NORMALITZATS) PER SETMANES EDIFICI RECTORAT


```

```{r}

#Afegir columna any

library(magrittr)

```


```

```

library(dplyr)

library(ggplot2)

df.RECTORAT.RECTORAT<-df.RECTORAT.RECTORAT %>%

  mutate(SetmanaAny=strftime(Group.1,"%Y-
%U"),HoraSetmana=as.numeric(strftime(Group.1,"%w"))*24+

      as.numeric(strftime(df.RECTORAT.RECTORAT$Group.1,"%H")))

#Normalització de connexions Wi-Fi i consum elèctric

df.RECTORAT.RECTORAT$WifiNormalitzat <- df.RECTORAT.RECTORAT$x /
max(df.RECTORAT.RECTORAT$x)

df.RECTORAT.RECTORAT$ConsumNormalitzat <- df.RECTORAT.RECTORAT$V4 /
max(df.RECTORAT.RECTORAT$V4)

#Dates inicial i final a graficar

data_ini <- as.Date("2016-11-26")

data_final <- as.Date("2016-12-31")

#Graficar les dades en múltiples gràfics agrupats segons el vector SetmanaAny

df.RECTORAT.RECTORAT %>% # using the user1 data frame

  filter(

    #Filtratge del període a traçar

    as.Date(Group.1) %>% between(data_ini,data_final)

  ) %>%

  ggplot(aes(x = as.numeric(HoraSetmana), y = as.numeric(WifiNormalitzat),
col="Connexions")) +

  geom_line(aes(y = as.numeric(ConsumNormalitzat), col="Consum")) +

  geom_line(col="darkblue") + #Gràfic del número de connexions respecte el temps

  facet_wrap(~SetmanaAny) + #Agrupar en setmanes

```

```

labs(x = "Dies de la setmana", y = "Dispositius connectats", title = "Quantitat
de dispositius connectats") + #Noms dels eixos

annotate("rect", xmin = 0 , xmax = 24, ymin = -Inf, ymax = Inf, #Àrea colorejada
pels diumenges

alpha = .2)+

annotate("rect", xmin = 144 , xmax = 168, ymin = -Inf, ymax = Inf, #Àrea
colorejada pels dissabtes

alpha = .1)+

# format de les marques de l'eix de les x

scale_x_continuous(limits=c(0,168),breaks = seq(0,168,24),labels =
c("du","dl","dm","dx","dj","dv","ds",""))+

#format del text de les marques x i dels títols dels eixos

theme(axis.text.x=element_text(size =13,angle =
315),axis.title.x=element_text(size = 13),

axis.title.y=element_text(size = 13))+

#format del títol del gràfic

theme(plot.title = element_text(size = 14,vjust = 1))

```

```

```

```

GRÀFIC PER SETMANES CREA (CAPPONT)

```

``` {r}

```

```

#Afegir columna any

```

```

library(magrittr)

```

```

library(dplyr)

```

```

df. CAPPONT. CREA<-df. CAPPONT. CREA %>%

```

```

mutate(SetmanaAny=strftime(Group.1,"%Y-
%U"),HoraSetmana=as.numeric(strftime(Group.1,"%w"))*24+

```

```

as.numeric(strftime(df.CAPPONT.CREA$Group.1,"%H")))

#Dates inicial i final a graficar

data_ini <- as.Date("2016-11-26")

data_final <- as.Date("2016-12-31")


#Graficar les dades en múltiples gràfics agrupats segons el vector SetmanaAny

df.CAPPONT.CREA %>% # using the user1 data frame

  filter(

    #Filtratge del període a traçar

    as.Date(Group.1) %>% between(data_ini,data_final)

  ) %>%

  ggplot(aes(x =as.numeric(HoraSetmana), y =as.numeric(x))) +

    geom_line(col="darkblue") + #Gràfic del número de connexions respecte el temps

    facet_wrap(~SetmanaAny) + #Agrupar en setmanes

    labs(x = "Dies de la setmana", y = "Dispositius connectats", title = "Número de
dispositius connectats") + #Noms dels eixos

    annotate("rect", xmin =0 , xmax = 24, ymin = -Inf, ymax = Inf, #Àrea colorejada
pels diumenges

    alpha = .2)+

    annotate("rect", xmin =144 , xmax = 168, ymin = -Inf, ymax = Inf, #Àrea
colorejada pels dissabtes

    alpha = .1)+

    # format de les marques de l'eix de les x

    scale_x_continuous(limits=c(0,168),breaks = seq(0,168,24),labels =
c("du","dl","dm","dx","dj","dv","ds",""))+

    #format del text de les marques x i dels títols dels eixos

```

```

    theme(axis.text.x=element_text(size =13,angle =
315),axis.title.x=element_text(size = 13),

    axis.title.y=element_text(size = 13))+

    #format del títol del gràfic

    theme(plot.title = element_text(size = 14,vjust = 1))

...

```

GRÀFIC COMPARATIU CONNEXIONS – CONSUM (NORMALITZATS) PER SETMANES EDIFICI CREA

```

```{r}

#Afegir columna any

library(magrittr)

library(dplyr)

library(ggplot2)

df.CAPPONT.CREA <- df.CAPPONT.CREA %>%

 mutate(SetmanaAny=strftime(Group.1,"%Y-
%U"),HoraSetmana=as.numeric(strftime(Group.1,"%w"))*24+

 as.numeric(strftime(df.CAPPONT.CREA$Group.1,"%H")))

#Normalització de connexions Wi-Fi i consum elèctric

df.CAPPONT.CREA$WifiNormalitzat <- df.CAPPONT.CREA$x / max(df.CAPPONT.CREA$x)

df.CAPPONT.CREA$ConsumNormalitzat <- df.CAPPONT.CREA$V4 / max(df.CAPPONT.CREA$V4)

#Dates inicial i final a graficar

data_ini <- as.Date("2016-11-26")

data_final <- as.Date("2016-12-31")

#Graficar les dades en múltiples gràfics agrupats segons el vector SetmanaAny

```

```

df.CAPPONT.CREA %>% # using the user1 data frame

 filter(

 #Filtratge del període a traçar

 as.Date(Group.1) %>% between(data_ini,data_final)

) %>%

 ggplot(aes(x = as.numeric(HoraSetmana), y = as.numeric(WifiNormalitzat),
col="Connexions")) +

 geom_line(aes(y = as.numeric(ConsumNormalitzat), col="Consum")) +

 geom_line(col="darkblue") + #Gràfic del número de connexions respecte el temps

 facet_wrap(~SetmanaAny) + #Agrupar en setmanes

 labs(x = "Dies de la setmana", y = "Dispositius connectats", title = "Quantitat
de dispositius connectats") + #Noms dels eixos

 annotate("rect", xmin =0 , xmax = 24, ymin = -Inf, ymax = Inf, #Àrea colorejada
pels diumenges

 alpha = .2)+

 annotate("rect", xmin =144 , xmax = 168, ymin = -Inf, ymax = Inf, #Àrea
colorejada pels dissabtes

 alpha = .1)+

 # format de les marques de l'eix de les x

 scale_x_continuous(limits=c(0,168),breaks = seq(0,168,24),labels =
c("du","dl","dm","dx","dj","dv","ds",""))+

 #format del text de les marques x i dels títols dels eixos

 theme(axis.text.x=element_text(size =13,angle =
315),axis.title.x=element_text(size = 13),

 axis.title.y=element_text(size = 13))+

 #format del títol del gràfic

 theme(plot.title = element_text(size = 14,vjust = 1))

```

```
```
```

GRÀFIC DE DISPERSIÓ RECTORAT (ORIGINAL)

```
``` {r}
```

#GRÀFIC DE DISPERSIÓ

```
library(ggplot2)
```

```
ggplot(df.RECTORAT.RECTORAT, aes(x = x, y = V4)) +
```

```
 geom_point(shape=1) + # Usar cercles buits
```

```
 geom_smooth(method=lm) + # Afegir línia de regressió lineal
```

```
 labs(x = "Dispositius connectats Wi-Fi", y = "Consum elèctric [kWh]")
```

```
 # (Per defecte inclou regió de confiança del 95%)
```

```
```
```

GRÀFIC DE DISPERSIÓ RECTORAT

```
``` {r}
```

\*\*\*GRÀFIC DE DISPERSIÓ I REGRESSIÓ LINEAL\*\*\*

```
library(magrittr)
```

```
linearPlot<-df.RECTORAT.RECTORAT %>% ##### Si treus el símbol, has de posar:
dftr$temperature o value
```

```
ggplot() +
```

```
 geom_point(aes(x=as.numeric(x),y =as.numeric(V4)),na.rm = T) + #Dispositius
connectats a l'eix x, consum elèctric a l'y
```

```
 #facet_wrap(~WeekHour,ncol = 24) + # Grouped in hours
```



```

labs(x = "Dispositius connectats Wi-Fi", y = "[KWh]") +

#geom_smooth(aes(x=as.numeric(x),y =as.numeric(V4)),

 #formula= y~x, method="lm", # Add linear regression lines

se= TRUE, # Don't add shaded confidence region

#fullrange=TRUE, na.rm=TRUE) + # Extend regression lines

theme_bw()+theme(plot.title = element_text(size = 12,vjust = 1))

#ggsave('figures/linearPlot.pdf',linearPlot, width = 45,height=18, units =
"cm",dpi=300) #save the heat map as a pdf file

plot(linearPlot)

```

```

GRÀFIC DE DISPERSIÓ CREA (ORIGINAL)

```
```{r}
```

#GRÀFIC DE DISPERSIÓ

```

library(ggplot2)

ggplot(df.CAPPONT.CREA, aes(x = x, y = V4)) +

 geom_point(shape=1) + # Usar cercles buits

 geom_smooth(method=lm) + # Afegir línia de regressió lineal

labs(x = "Dispositius connectats Wi-Fi", y = "Consum elèctric [kWh]")

(Per defecte inclou regió de confiança del 95%)

```

```

GRÀFIC DE DISPERSIÓ CREA

```
```{r}
```

\*\*\*GRÀFIC DE DISPERSIÓ I REGRESSIÓ LINEAL\*\*\*

```
library(magrittr)

linearPlot<-df.CAPPONT.CREA %>% ##### Si treus el símbol, has de posar:
dftr$temperature o value

 ggplot() +

 geom_point(aes(x=as.numeric(x),y =as.numeric(V4)),na.rm = T) + #Dispositius
connectats a l'eix x, consum elèctric a l'y

 #facet_wrap(~WeekHour,ncol = 24) + # Grouped in hours

 labs(x = "Dispositius connectats Wi-Fi", y = "[KWh]") +

 #geom_smooth(aes(x=as.numeric(x),y =as.numeric(V4)),

 #formula= y~x, method="lm", # Add linear regression lines

 # se= TRUE, # Don't add shaded confidence region

 #fullrange=TRUE, na.rm=TRUE) + # Extend regression lines

 theme_bw()+theme(plot.title = element_text(size = 12,vjust = 1))

#ggsave('figures/linearPlot.pdf',linearPlot, width = 45,height=18, units =
"cm",dpi=300) #save the heat map as a pdf file

plot(linearPlot)

```
```

INFORMACIÓ ESTADÍSTICA

```
```{r}

#R^2 Rectorat i CREA

R2.RECTORAT.RECTORAT <- cor(df.RECTORAT.RECTORAT$x, df.RECTORAT.RECTORAT$V4, method
= "pearson")^2

R2.CAPPONT.CREA <- cor(df.CAPPONT.CREA$x, df.CAPPONT.CREA$V4, method = "pearson")^2

```
```

```
```{r}
```

```
MODLIN.RECTORAT <- lm(df.RECTORAT.RECTORAT$V4 ~ df.RECTORAT.RECTORAT$x)
```

```
plot(MODLIN.RECTORAT)
```

```
acf(df.RECTORAT.RECTORAT$x, df.RECTORAT.RECTORAT$V4, plot=TRUE)
```

```
```
```

```
```{r}
```

```
MODLIN.CREA <- lm(df.CAPPONT.CREA$V4 ~ df.CAPPONT.CREA$x)
```

```
plot(MODLIN.CREA)
```

```
acf(df.CAPPONT.CREA$x, df.CAPPONT.CREA$V4, plot=TRUE)
```

```
```
```

CREACIÓ DE DATAFRAMES SENSE DIES DE TANCAMENT

```
```{r}
```

```
#RECTORAT
```

```
#ELIMINACIÓ 25, 26 I 31 DE DESEMBRE
```

```
df.RECTORAT.RECTORAT.OBERTS <- subset(df.RECTORAT.RECTORAT, DiaSetmana <= "5" &
DiaSetmana >= "2" | SetmanaAny != "2016-52")
```

```
#26 DE DESEMBRE
```

```
#df.RECTORAT.RECTORAT.OBERTS <- subset(df.RECTORAT.RECTORAT.OBERTS, DiaSetmana >=
"2" | SetmanaAny != "2016-52")
```

```
#24 DE DESEMBRE
```

```
df.RECTORAT.RECTORAT.OBERTS <- subset(df.RECTORAT.RECTORAT.OBERTS, DiaSetmana != "6"
| SetmanaAny != "2016-51")
```

```

#CREA

#ELIMINACIÓ CAPS DE SETMANA

df.CAPPONT.CREA.OBERTS <- subset(df.CAPPONT.CREA, DiaSetmana <="5")

#6, 8 I 9 DE DESEMBRE

df.CAPPONT.CREA.OBERTS <- subset(df.CAPPONT.CREA.OBERTS, DiaSetmana == "1" |
DiaSetmana == "3" | SetmanaAny != "2016-49")

#23 DE DESEMBRE

df.CAPPONT.CREA.OBERTS <- subset(df.CAPPONT.CREA.OBERTS, DiaSetmana != "5" |
SetmanaAny != "2016-51")

#26 DE DESEMBRE

df.CAPPONT.CREA.OBERTS <- subset(df.CAPPONT.CREA.OBERTS, DiaSetmana != "1" |
SetmanaAny != "2016-52")

#13, 14 I 15 DE DESEMBRE (LECTURES DE CONSUM SOSPITOSSES)

df.CAPPONT.CREA.OBERTS <- subset(df.CAPPONT.CREA.OBERTS, DiaSetmana == "5" |
DiaSetmana == "1" | SetmanaAny != "2016-50")

...

```

## GRÀFIC PER SETMANES RECTORAT OBERTS

```

...{r}

#Afegir columnes SetmanaAny, DiaSetmana i HoraSetmana

library(magrittr)

library(dplyr)

library(ggplot2)

#Graficar les dades en múltiples gràfics agrupats segons el vector SetmanaAny

df.RECTORAT.RECTORAT.OBERTS %>% # using the user1 data frame

```

```

filter(

 #Filtratge del període a traçar

 as.Date(Group.1) %>% between(data_ini,data_final)

) %>%

ggplot(aes(x =as.numeric(HoraSetmana), y =as.numeric(x))) +

 geom_line(col="darkblue") + #Gràfic del número de connexions respecte el temps

 facet_wrap(~SetmanaAny) + #Agrupar en setmanes

 labs(x = "Dies de la setmana", y = "Dispositius connectats", title = "Número de
dispositius connectats") + #Noms dels eixos

 annotate("rect", xmin =0 , xmax = 24, ymin = -Inf, ymax = Inf, #Àrea colorejada
pels diumenges

 alpha = .2)+

 annotate("rect", xmin =144 , xmax = 168, ymin = -Inf, ymax = Inf, #Àrea
colorejada pels dissabtes

 alpha = .1)+

 # format de les marques de l'eix de les x

 scale_x_continuous(limits=c(0,168),breaks = seq(0,168,24),labels =
c("du","dl","dm","dx","dj","dv","ds",""))+

 #format del text de les marques x i dels títols dels eixos

 theme(axis.text.x=element_text(size =13,angle =
315),axis.title.x=element_text(size = 13),

 axis.title.y=element_text(size = 13))+

 #format del títol del gràfic

 theme(plot.title = element_text(size = 14,vjust = 1))

...

```

GRÀFIC COMPARATIU CONNEXIONS – CONSUM (NORMALITZATS) PER SETMANES RECTORAT OBERTS

```

```{r}

#Afegir columna any

library(magrittr)

library(dplyr)

library(ggplot2)

#Graficar les dades en múltiples gràfics agrupats segons el vector SetmanaAny

df.RECTORAT.RECTORAT.OBERTS %>% # using the user1 data frame

  filter(

    #Filtratge del període a traçar

    as.Date(Group.1) %>% between(data_ini,data_final)

  ) %>%

  ggplot(aes(x = as.numeric(HoraSetmana), y = as.numeric(WifiNormalitzat),
col="Connexions")) +

  geom_line(aes(y = as.numeric(ConsumNormalitzat), col="Consum")) +

  geom_line(col="darkblue") + #Gràfic del número de connexions respecte el temps

  facet_wrap(~SetmanaAny) + #Agrupar en setmanes

  labs(x = "Dies de la setmana", y = "Dispositius connectats", title = "Quantitat
de dispositius connectats") + #Noms dels eixos

  annotate("rect", xmin =0 , xmax = 24, ymin = -Inf, ymax = Inf, #Àrea colorejada
pels diumenges

    alpha = .2)+

  annotate("rect", xmin =144 , xmax = 168, ymin = -Inf, ymax = Inf, #Àrea
colorejada pels dissabtes

    alpha = .1)+

  # format de les marques de l'eix de les x

  scale_x_continuous(limits=c(0,168),breaks = seq(0,168,24),labels =
c("du","dl","dm","dx","dj","dv","ds",""))+

```

```

#format del text de les marques x i dels títols dels eixos

theme(axis.text.x=element_text(size =13,angle =
315),axis.title.x=element_text(size = 13),

axis.title.y=element_text(size = 13))+

#format del títol del gràfic

theme(plot.title = element_text(size = 14,vjust = 1))
...

```

GRÀFIC DE DISPERSIÓ RECTORAT OBERTS

```

... {r}

library(ggplot2)

ggplot(df.RECTORAT.RECTORAT.OBERTS, aes(x = x, y = V4)) +

  geom_point(shape=1) + # Usar cercles buits

  geom_smooth(method=lm, fullrange = TRUE) + # Afegir línia de regressió lineal

  labs(x = "Dispositius connectats Wi-Fi", y = "Consum elèctric [kWh]")

  # (Per defecte inclou regió de confiança del 95%)
...

```

GRÀFIC PER SETMANES CREA OBERTS

```

... {r}

#Afegir columnes SetmanaAny, DiaSetmana i HoraSetmana

library(magrittr)

library(dplyr)

library(ggplot2)

#Graficar les dades en múltiples gràfics agrupats segons el vector SetmanaAny

```

```

df.CAPPONT.CREA.OBERTS %>% # using the user1 data frame

  filter(

    #Filtratge del període a traçar

    as.Date(Group.1) %>% between(data_ini,data_final)

  ) %>%

  ggplot(aes(x =as.numeric(HoraSetmana), y =as.numeric(x))) +

    geom_line(col="darkblue") + #Gràfic del número de connexions respecte el temps

    facet_wrap(~SetmanaAny) + #Agrupar en setmanes

    labs(x = "Dies de la setmana", y = "Dispositius connectats", title = "Número de
dispositius connectats") + #Noms dels eixos

    annotate("rect", xmin =0 , xmax = 24, ymin = -Inf, ymax = Inf, #Àrea colorejada
pels diumenges

      alpha = .2)+

    annotate("rect", xmin =144 , xmax = 168, ymin = -Inf, ymax = Inf, #Àrea
colorejada pels dissabtes

      alpha = .1)+

    # format de les marques de l'eix de les x

    scale_x_continuous(limits=c(0,168),breaks = seq(0,168,24),labels =
c("du","dl","dm","dx","dj","dv","ds",""))+

    #format del text de les marques x i dels títols dels eixos

    theme(axis.text.x=element_text(size =13,angle =
315),axis.title.x=element_text(size = 13),

      axis.title.y=element_text(size = 13))+

    #format del títol del gràfic

    theme(plot.title = element_text(size = 14,vjust = 1))

  ...

```


GRÀFIC COMPARATIU CONNEXIONS - CONSUM (NORMALITZATS) PER SETMANES CREA OBERTS

```

```{r}

library(magrittr)

library(dplyr)

library(ggplot2)

#Graficar les dades en múltiples gràfics agrupats segons el vector SetmanaAny

df.CAPPONT.CREA.OBERTS %>% # using the user1 data frame

 filter(

 #Filtratge del període a traçar

 as.Date(Group.1) %>% between(data_ini,data_final)

) %>%

 ggplot(aes(x = as.numeric(HoraSetmana), y = as.numeric(WifiNormalitzat),
col="Connexions")) +

 geom_line(aes(y = as.numeric(ConsumNormalitzat), col="Consum")) +

 geom_line(col="darkblue") + #Gràfic del número de connexions respecte el temps

 facet_wrap(~SetmanaAny) + #Agrupar en setmanes

 labs(x = "Dies de la setmana", y = "Dispositius connectats", title = "Quantitat
de dispositius connectats") + #Noms dels eixos

 annotate("rect", xmin =0 , xmax = 24, ymin = -Inf, ymax = Inf, #Àrea colorejada
pels diumenges

 alpha = .2)+

 annotate("rect", xmin =144 , xmax = 168, ymin = -Inf, ymax = Inf, #Àrea
colorejada pels dissabtes

 alpha = .1)+

 # format de les marques de l'eix de les x

 scale_x_continuous(limits=c(0,168),breaks = seq(0,168,24),labels =
c("du","dl","dm","dx","dj","dv","ds",""))+

```

```

#format del text de les marques x i dels títols dels eixos

theme(axis.text.x=element_text(size =13,angle =
315),axis.title.x=element_text(size = 13),

axis.title.y=element_text(size = 13))+

#format del títol del gràfic

theme(plot.title = element_text(size = 14,vjust = 1))

```

```

```

```

GRÀFIC DE DISPERSIÓ RECTORAT OBERTS

```

```{r}

library(ggplot2)

ggplot(df.CAPPONT.CREA.OBERTS, aes(x = x, y = V4)) +

 geom_point(shape=1) + # Usar cercles buits

 geom_smooth(method=lm, fullrange = TRUE) + # Afegir línia de regressió lineal

 labs(x = "Dispositius connectats Wi-Fi", y = "Consum elèctric [kWh]")

 # (Per defecte inclou regió de confiança del 95%)

```

```

```

```

INFORMACIÓ ESTADÍSTICA SENSE DIES DE TANCAMENT

```

```{r}

#R^2 Rectorat i CREA

R2.RECTORAT.RECTORAT.OBERTS <- cor(df.RECTORAT.RECTORAT.OBERTS$x,
df.RECTORAT.RECTORAT.OBERTS$V4, method = "pearson")^2

R2.CAPPONT.CREA.OBERTS <- cor(df.CAPPONT.CREA.OBERTS$x, df.CAPPONT.CREA.OBERTS$V4,
method = "pearson")^2

```

```

```

```

```
```{r}
```

```
MODLIN.RECTORAT.OBERTS <- lm(df.RECTORAT.RECTORAT.OBERTS$V4 ~
df.RECTORAT.RECTORAT.OBERTS$x)

plot(MODLIN.RECTORAT.OBERTS)

acf(df.RECTORAT.RECTORAT.OBERTS$x, df.RECTORAT.RECTORAT.OBERTS$V4, plot=TRUE)
```
```

```
```{r}
```

```
MODLIN.CREA.OBERTS <- lm(df.CAPPONT.CREA.OBERTS$V4 ~ df.CAPPONT.CREA.OBERTS$x)

plot(MODLIN.CREA.OBERTS)

acf(df.CAPPONT.CREA.OBERTS$x, df.CAPPONT.CREA.OBERTS$V4, plot=TRUE)
```
```